УДК 004.942:623.746-519 **DOI:** 10.31673/2412-9070.2026.051315

М. С. БОВСУНІВСЬКИЙ, студент;
ORCID: 0009-0001-6677-1532
К. О. ДОМРАЧЕВА, канд. техн. наук, доцент;
ORCID: 0000-0001-6126-7698
Р. М. КИРИЧЕНКО, ст. викл.,
ORCID: 0009-0006-2586-2493
Державний університет інформаційно-комунікаційних технологій, Київ

ІНТЕЛЕКТУАЛЬНІ МЕТОДИ УНИКНЕННЯ ЗІТКНЕНЬ У ГРУПОВИХ ПОЛЬОТАХ БПЛА НА ОСНОВІ РЛС: ГІБРИДНИЙ ПІДХІД З ВИКОРИСТАННЯМ ПРОГНОЗУВАННЯ ТРАЄКТОРІЙ ТА ФЕДЕРАТИВНОЇ АДАПТАЦІЇ

У статті розглянуто одну з ключових проблем сучасних багатоагентних роботизованих систем - забезпечення гарантованої безпеки групового польоту безпілотних літальних апаратів (БПЛА) в умовах високої щільності рою, наявності динамічних перешкод і часткової спостережуваності середовища. Обґрунтовано недоліки традиційних підходів: штучні потенційні поля (APF) є суто реактивними й схильними до локальних мінімумів, а геометричні методи (ORCA) засновані на припущенні про сталість швидкостей, що призводить до надмірного консерватизму та тупикових станів. Запропоновано нову гібридну децентралізовану систему уникнення зіткнень AI-RDR.

Методологія дослідження базується на поетапній інтеграції чотирьох технологічних рівнів: (1) бортового сенсорного сприйняття на основі FMCW радара, робастного до погодних умов; (2) прогнозування нелінійних траєкторій сусідніх агентів за допомогою рекурентної мережі Attention-Bi-GRU; (3) децентралізованого планування безпечного шляху в неперервному 3D-просторі за допомогою модифікованого алгоритму мурашиних колоній (ACO), який використовує ймовірнісний прогноз як евристику ризику; (4) колективної адаптації моделей у рої на основі алгоритму федеративного навчання FedProx, що забезпечує стабільну збіжність на неоднорідних (не-IID) даних без централізації сирих вимірювань.

Експериментальна перевірка виконана в середовищі високоточного моделювання Gazebo 11 з інтеграцією автопілота PX4 у режимі SITL і модулів ROS 2. Результати порівняльного аналізу довели, що запропонований метод досягає коефіцієнта успішності (SR) понад 99,8% у складних динамічних сценаріях, суттєво перевершуючи APF та ORCA. Система демонструє більший запас безпечної відстані (AMD = 4,8 м) і високу ефективність шляху (PE = 0,92) за затримки циклу прийняття рішень у межах 45 мс, що підтверджує придатність для роботи в реальному часі. Наукова новизна полягає у формуванні синергетичної архітектури, де прогнозування безпосередньо впливає на ризик-орієнтоване планування, та в застосуванні FedProx для адаптації прогностичних моделей у роях БПЛА.

Ключові слова: рій БПЛА, уникнення зіткнень, FMCW радар, штучний інтелект, прогнозування траєкторій, Attention-Bi-GRU, алгоритм мурашиних колоній, федеративне навчання, FedProx, проактивна навігація, ROS 2, Gazebo/PX4.

Постановка проблеми

Безпрецедентні можливості відкриваються зі швидким розвитком безпілотних авіаційних систем (БПЛА) та групових утворень, до яких вони інтегруються, зокрема, у моніторингу польових зон, пошуково-рятувальних операціях, точному землеробстві та логістиці [1]. Це робить технологію роїв БПЛА стратегічно важливою: ройові БПЛА виконують складні скоординовані місії, що виходять за межі можливостей окремих літальних апаратів. Однак існує фун-

© Бовсунівський М. С., Домрачева К. О., Кириченко Р. М., 2026

даментальна перешкода для масштабних автономних роїв - надійна навігація та запобігання зіткненням у щільних, динамічних, неструктурованих середовищах.

Існуючі підходи поділяються на дві основні категорії, кожна з яких має суттєві обмеження. Методи, засновані на концепції штучних потенційних полів (ШПП або APF), моделюють рух БПЛА у відповідь на віртуальні сили - притягування до цілі та відштовхування від перешкод. Незважаючи на обчислювальну простоту, вони страждають від проблем локальних мінімумів, коли БПЛА «застрягає» в балансі сил, а також від недосяжності цілі, розташованої поблизу перешкоди [3]. З іншого боку, геометричні методи, такі як швидкісні перешкоди (Velocity Obstacles, VO) та їх вдосконалені версії (наприклад, ORCA), визначають множину небезпечних швидкостей, що призводять до зіткнення [5]. Ці методи базуються на критичному припущенні про лінійний рух інших агентів, що рідко виконується в реальних динамічних роях, і призводять до надмірно консервативної поведінки, зупинок або повного глухого кута в щільних сценаріях.

Для подолання фундаментальних обмежень існуючих методів необхідний інтелектуальний гібридний підхід, який поєднує надійність радіолокаційного зондування (РЛС) з можливостями штучного інтелекту для нелінійного прогнозування траєкторій та колективної адаптації.

Аналіз останніх досліджень і публікацій

Проблема запобігання зіткненням у багатоагентних системах, зокрема роях БПЛА, є активною дослідницькою областю. Традиційні підходи можна умовно розділити на оптимізаційні, геометричні та біо-натхненні методи [11], [12].

Методи на основі штучних потенційних полів (APF), запропоновані Хатібом, залишаються популярними через свою простоту та низькі обчислювальні витрати [3], [24]. Однак їх фундаментальні недоліки, такі як локальні мінімуми та недосяжність цілі поблизу перешкоди (GNRON), обмежують застосування в складних динамічних середовищах. Подальші модифікації APF, спрямовані на усунення цих проблем, часто призводять до підвищення обчислювальної складності або втрати гарантій безпеки [28].

Геометричні методи, зокрема концепція швидкісних перешкод (VO) та її розвиток у формі оптимального взаємного уникнення зіткнень (ORCA), запропонований ван ден Бергом та ін. [23], здійснили значний крок вперед. Вони формалізують задачу у просторі швидкостей та здатні генерувати безпечні та плавні траєкторії для десятків агентів у реальному часі. Критичним обмеженням ORCA та подібних методів є припущення про постійну швидкість інших агентів на горизонті планування, що робить їх надмірно консервативними або неефективними в середовищах з високою динамікою та нелінійними траєкторіями, типовими для роїв БПЛА, що виконують маневри [18].

Біо-натхненні алгоритми, такі як алгоритм мурашиних колоній (ACO) [9], [31] або зграї птахів, запропоновані для планування шляху, демонструють хорошу здатність до глобального пошуку та адаптації. Однак їх застосування для запобігання зіткненням у реальному часі ускладнене високою обчислювальною складністю та труднощами інтеграції з даними датчиків у режимі реального часу [32].

Останнім часом з'явилися дослідження, що інтегрують методи машинного навчання, зокрема рекурентні нейронні мережі (RNN), для прогнозування траєкторій у контексті автономного транспорту та БПЛА [10], [25], [26]. Моделі на основі LSTM та GRU демонструють високу точність у передбаченні нелінійного руху. Однак більшість цих робіт зосереджена на прогнозуванні як на окремій задачі, а не на її безпосередній інтеграції в замкнутий контур планування та управління для рою.

Парадигма федеративного навчання (FL) визначається як перспективний підхід для колективного навчання в розподілених системах, таких як рої БПЛА, без необхідності обміну сирими даними, що зберігає конфіденційність та зменшує навантаження на зв'язок [5], [13], [17]. Алгоритм FedProx був спеціально розроблений для подолання проблеми неоднорідних (не-IID) даних у федеративному навчанні [13], що робить його особливо актуальним для роїв, де дані кожного БПЛА унікальні. Проте література щодо застосування FedProx безпосередньо

для адаптації прогностичних моделей у реальному часі в системах запобігання зіткненням БПЛА обмежена або відсутня.

Мета і задачі дослідження

Метою даного дослідження є розробка, реалізація та експериментальна перевірка нової гібридної інтелектуальної системи запобігання зіткненням для автономних роїв БПЛА. Система повинна забезпечувати проактивну, надійну та масштабовану роботу шляхом інтеграції радіолокаційного сприйняття, прогнозування траєкторій на основі нейронних мереж, децентралізованого планування шляху та механізму федеративної адаптації.

Для досягнення поставленої мети були визначені наступні задачі:

1. Розробити децентралізовану архітектуру системи, яка інтегрує наступні компоненти на кожному БПЛА:
   - Модуль сприйняття на основі бортового FMCW радара.
   - Прогностичну модель на основі двонаправленої рекурентної нейронної мережі з увагою (Attention-Bi-GRU) для оцінки нелінійних траєкторій сусідніх агентів.
   - Планувальник шляху на основі модифікованого алгоритму мурашиних колоній (ACO), що оптимізує маршрут з урахуванням прогнозованих траєкторій.
   - Клієнта федеративного навчання на основі алгоритму FedProx для колективної адаптації прогностичних моделей рою.
2. Реалізувати запропоновану систему в середовищі високоточного моделювання Gazebo з інтеграцією автопілота PX4 у режимі SITL (Software-in-the-Loop).
3. Розробити набір складних тестових сценаріїв, що імітують реальні загрози зіткнення в рої (лобова зустріч, перетин траєкторій, зміна формації, присутність динамічних перешкод).
4. Провести всебічний порівняльний аналіз ефективності запропонованого методу (AI-RDR) з двома основним традиційними підходами: методом штучних потенційних полів (APF) та методом оптимального взаємного уникнення зіткнень (ORCA). Критерії оцінки повинні включати: коефіцієнт успішності запобігання зіткненням, середню мінімальну відстань між агентами, ефективність пройденого шляху, обчислювальну затримку та масштабованість із зростанням розміру рою.

Методика експерименту.

Експериментальна оцінка системи проводилася в середовищі моделювання Gazebo 11, інтегрованому з автопілотом PX4 у режимі Software-in-the-Loop (SITL). Це забезпечує високореалістичну фізику польоту, роботу датчиків та виконання того ж програмного коду, що й на реальному апаратному забезпеченні.

Апаратне та програмне забезпечення моделювання:

- Симуляційне середовище: Gazebo 11, PX4 Autopilot SITL v1.14.
- Модель БПЛА: Стандартна модель квадрокоптера Iris.
- Модель радара: Віртуальний FMCW радар із параметрами, наведеними в Таблиці 1.
- Програмні компоненти: Система реалізована як набір вузлів ROS 2 (Humble), що включає драйвер радара, модуль прогнозування (PyTorch), модуль планування ACO та клієнта FL. Комунікація з автопілотом здійснюється через MAVLink за допомогою MAVROS.
- Обчислювальна платформа: Експерименти проводилися на ПК з CPU Intel Core i7-12700, GPU NVIDIA RTX 3070, 32 ГБ ОЗП. Параметри моделювання наведені в Таблиці 1.

Сценарії тестування: Для перевірки було розроблено чотири складні сценарії:

1. Лобова зустріч: Дві групи БПЛА (по N/2 апаратів) летять назустріч одна одній по прямій лінії.
2. Перпендикулярне перетин: Дві групи перетинають траєкторії під кутом 90° на одній висоті.
3. Динамічна зміна формації: Рій із 25 БПЛА виконує перебудову з лінійного у кубічне формування в просторі зі статичними та динамічними перешкодами.
4. Зустріч із стороннім агентом: У середовище вводиться один БПЛА, що виконує непередбачувані маневри, для перевірки адаптивності прогностичної моделі.

Таблиця 1

Параметри моделювання для перевірки ефективності системи

Група параметрів	Параметр	Значення
Середовище	Розмір симуляційного простору	500 x 500 x 100 м
	Кількість БПЛА в рої	Варіюється: 5, 10, 15, 20, 25
	Кількість динамічних перешкод	5 (із випадковими траєкторіями)
Модель БПЛА	Тип	Квадрокоптер (модель Iris)
	Максимальна швидкість	15 м/с
	Максимальне прискорення	5 м/с²
Модель сенсора	Тип РЛС	FMCW
	Максимальна дальність	150 м
	Роздільна здатність за дальністю	0.2 м
	Роздільна здатність за швидкістю	0.1 м/с
	Частота оновлення	20 Гц
Параметри ШІ	Архітектура RNN	Bi-GRU, 2 шари, 128 нейронів
	Параметри ACO	К-ть мурах: 50; Коеф. Випар.: 0.1
	Параметри FL (FedProx)	К-ть раундів: 50; Лок. еп.: 5; μ: 0.01

Метрики оцінки:

- Коефіцієнт успішності (Success Rate, SR): Відсоток симуляційних запусків, завершених без жодного зіткнення.
- Середня мінімальна відстань (Average Minimum Distance, AMD): Середнє значення мінімальної відстані, зафіксованої між будь-якою парою БПЛА за час виконання сценарію.
- Ефективність шляху (Path Efficiency, PE): Відношення довжини оптимального (прямого) шляху до фактичної пройденої відстані.
- Обчислювальна затримка (Computational Latency, CL): Середній час (мс), необхідний для одного циклу прийняття рішення (сприйняття-прогноз-планування) на бортовому комп'ютері.
- Аналіз масштабованості: Залежність ймовірності зіткнення (1-SR) від кількості БПЛА у рої.

Задачу уникнення зіткнень можна формалізувати як частково спостережувану децентралізовану задачу оптимізації в багатоагентній системі. Нехай у рої є N БПЛА, і в будь-який момент часу t стан кожного агента і задається вектором $\mathbf{s}_i(\mathbf{t}) = \left[\mathbf{p}_i(\mathbf{t}), \mathbf{v}_i(\mathbf{t}), \mathbf{R}_i(\mathbf{t})\right]$, де $\mathbf{p}_i$ – положення, $\mathbf{v}_i$ – швидкість, а $\mathbf{R}_i \in SO(3)$ – матриця орієнтації для БПЛА i. Кожен БПЛА вважається сферою з радіусом r.

Нехай кожен агент i обчислює керуючу дію u_i(t) для мінімізації власної функції витрат J_i, що складається з членів пошуку пункту призначення, утримання формації та уникнення зіткнень. Умова уникнення зіткнень між будь-якими двома агентами i та j у будь-який момент часу t така:

$$\|\mathbf{p}_i(\mathbf{t}) - \mathbf{p}_j(\mathbf{t})\| > \mathbf{2r}, \quad (1)$$

де $\|\cdot\|$ - евклідова норма [5].

Ключовими викликами у вирішенні цієї проблеми є:

- Масштабованість: Обчислювальна складність зростає щонайменше квадратично з кількістю агентів. Це робить роботу в режимі реального часу для великого рою практично неможливою.
- Децентралізація: Кожен агент приймає рішення лише на основі доступної локальної інформації, оскільки повністю централізоване керування дуже схильне до збоїв і створює вузьке місце в комунікації [18].
- Невизначеність: Агенти працюють у середовищі, яке постійно змінюється. Інформація, що надається агентам, стосується намірів решти агентів та зовнішніх перешкод.

Прогалина в дослідженнях та обґрунтування нового підходу

Обмеження традиційних методів полягають не лише в недоліках реалізації, а й у фундаментальних недоліках їхніх парадигм. APF є суто реактивним, оскільки його стан визначається лише поточними позиціями, ігноруючи будь-яку кінематичну інформацію. VO робить крок вперед, враховуючи швидкість, але його модель прогнозування є лінійною та примітивною. Нелінійна, не така проста динаміка відповідає взаємодії рою.

Отже, для отримання успішної системи запобігання зіткненням слід провести більш детальне моделювання світу. Вона повинна бути:

- Проактивною: приймати рішення не на основі поточного стану, а на основі прогнозу майбутнього розвитку.
- Прогностичною: здатною передбачати нелінійні, складні траєкторії інших агентів.
- Адаптивною: здатною навчатися та адаптувати свою поведінку відносно конкретних умов навколишнього середовища та динаміки конкретного рою.

Ці вимоги чітко визначають прогалину в дослідженнях і виправдовують розробку нового підходу гібридного інтелекту, який поєднує надійні дані датчиків з потужними методами штучного інтелекту для прогнозування, планування та адаптації.

Гібридний інтелектуальний метод

Для запуску циклу прогнозування-планування адаптації сприйняття на кожному БПЛА впроваджено інтегровану децентралізовану систему. Запропонована система поєднує бортові радіолокаційні дані з трьома шарами штучного інтелекту – рекурентною нейронною мережею для прогнозування траєкторії, планування шляху колонії мурах та колективної адаптації на основі федеративного навчання.

Концептуальна архітектура системи

Запропонована архітектура є децентралізованою, причому кожен БПЛА діє як автономний агент прийняття рішень, але також є частиною колективного навчання, що забезпечує високу відмовостійкість та масштабованість. Основними компонентами, що працюють на кожному пристрої, є підсистема сприйняття на основі радара, модулі прогнозування та планування, а також модуль федеративної адаптації.

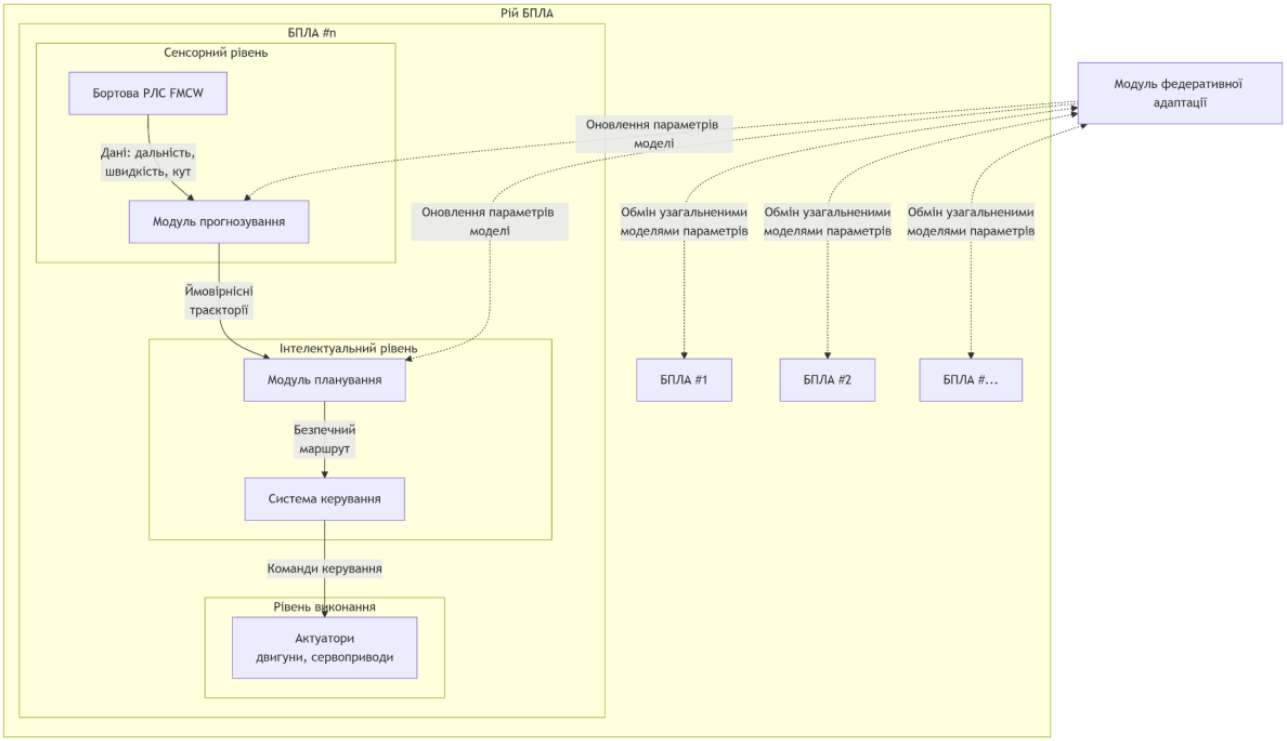


Рис. 1. Загальна архітектура запропонованої системи уникнення зіткнень

Підсистема обробки даних РЛС та прогнозування траєкторій

Основою будь-якої системи запобігання зіткненням є реальне сприйняття навколишнього середовища. Тому за будь-яких умов оптичні камери або лідари, чутливі до своїх параметрів, повинні включати освітлення, погодні умови, туман, дощ, пил, стабільну роботу радара [15]. Найважливішим серед них є параметр, який безпосередньо вимірюється радаром: відстань до об'єкта, відносна швидкість, зумовлена ефектом Доплера, та кутове положення об'єкта. Для потреб високої роздільної здатності на коротких та середніх відстанях навігаційних завдань у щільному рої найкраще підійде частотно-модульований радар безперервної хвилі (FMCW).

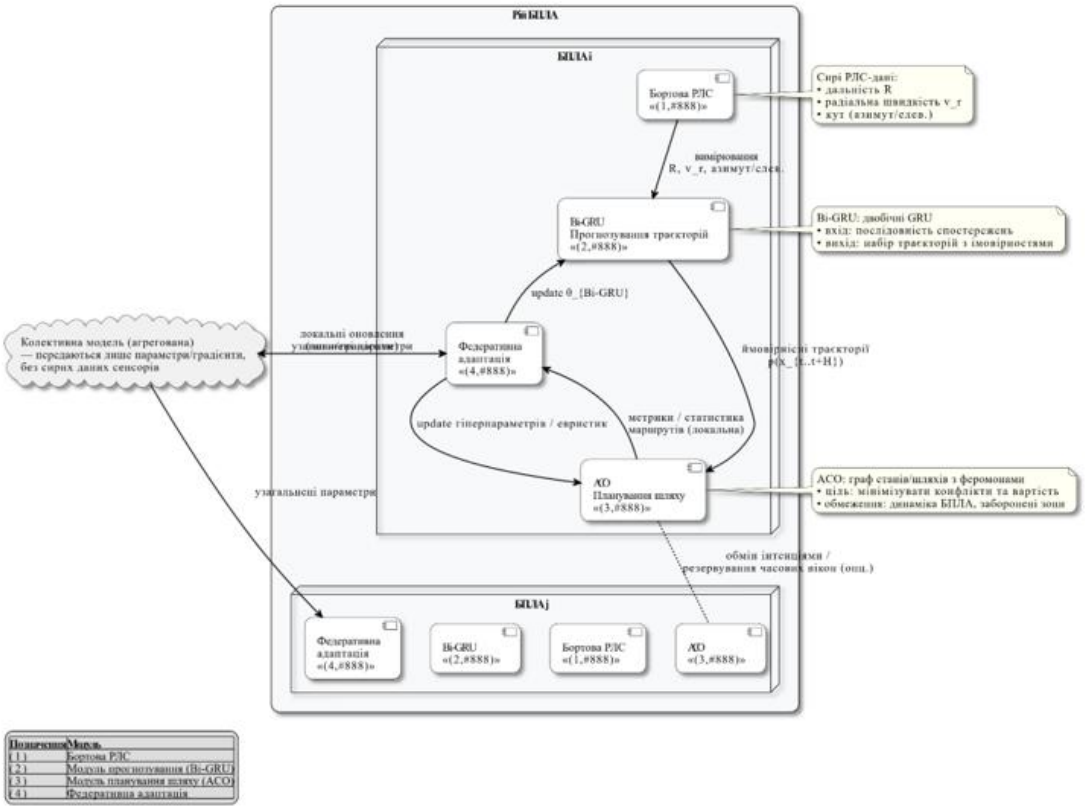


Рис. 2. Уточнена архітектура запропонованої системи уникнення зіткнень

Прогнозування за допомогою рекурентної нейронної мережі (RNN)

Вихідні дані радара можна описати як часову послідовність векторів [дальність, швидкість, кут]. Такі дані ідеально підходять для обробки рекурентними нейронними мережами, оскільки RNN здатні моделювати складні часові залежності. У цій статті пропонується використовувати двонаправлену стробіровану рекурентну мережу з одиницями (Bi-GRU). Модель GRU є більш ефективною в обчислювальному плані щодо LSTM та зберігає можливість виявлення довгострокових залежностей. Двонаправлена архітектура аналізує як прямий, так і зворотний проходи по вхідній послідовності; отже, вона краще фіксує контекст руху, що робить прогнозування точнішим [10].

Для подальшого підвищення точності в архітектуру інтегровано механізм уваги. Це означає, що модель може динамічно зважувати важливість різних часових кроків у вхідній послідовності. У випадку, якщо БПЛА поблизу здійснює раптовий маневр, цей механізм уваги надаватиме більшу вагу останнім вимірюванням, і, отже, буде отримано швидше та точніше прогнозування зміни траєкторії. Модель Bi-GRU видає не одну детерміністичну траєкторію, а розподіл ймовірностей між можливими майбутніми позиціями агента. Це дозволяє системі планування оцінювати ризики та вибирати маршрути з найнижчою ймовірністю конфлікту.

Децентралізоване планування шляху на основі мурашиних колоній (ACO)

Після отримання інформації про прогнозовану траєкторію руху сусідніх агентів, кожен БПЛА повинен обчислити для себе можливу траєкторію. Для цього використовується алго-

ритм колонії мурах (ACO), який належить до класу метаевристичних алгоритмів оптимізації та має доведені проблеми динамічного пошуку шляху.[12] Окрім природного паралелізму та можливості глобального оптимального рішення, що робить його придатним для реалізації на бортових обчислювальних платформах, у цій статті виділено ще одну перевагу ACO.

Оскільки класичний ACO працює на дискретних графах, для його застосування в неперервному 3D-просторі використовується підхід, подібний до ACO для неперервних областей. У цьому підході "мурахи" (пошукові агенти) не вибирають наступний вузол зі скінченної множини, а генерують (вибирають) наступну точку шляху з неперервного розподілу ймовірностей, який формується на основі "феромонного сліду" - архіву знайдених найкращих рішень.

Ключова інновація запропонованого методу полягає у формуванні евристичної функції для керування рухом "мурах". Окрім простого врахування відстані до пункту призначення, евристичний композит інтегрує інформацію з модуля прогнозування. Можлива вартість сегмента шляху обернено пропорційна його безпеці, яка визначається як ймовірність того, що цей сегмент не перетинатиметься з областями, зайнятими високою ймовірністю інших агентів, передбачених моделлю Bi-GRU. Отже, існує явний синергетичний зв'язок - підвищена точність прогнозування негайно призводить до створення безпечніших, а також ефективніших маршрутів. Система еволюціонує від простого реагування на основі того, де знаходиться поточна перешкода, до проактивного обходу (ймовірнісного) майбутньої траєкторії.

Федеративна адаптація для динамічного середовища

Щоб рій міг адаптуватися до нових умов, випадкових маневрів або певної динаміки навколишнього середовища, прогностичні моделі Bi-GRU повинні постійно оновлюватися. Централізоване накопичення даних усіх БПЛА для перенавчання моделі виявляється непрактичним через високі витрати на зв'язок, а також тому, що це створює кілька проблем із конфіденційністю. Таким чином, для децентралізованого навчання пропонується парадигма федеративного навчання (FL) [14].

У FL кожен БПЛА навчає свою локальну модель Bi-GRU на даних, отриманих від власних датчиків, і замість передачі необроблених даних на центральний сервер, між пристроями обмінюються лише оновленими параметрами (ваговими коефіцієнтами) їхніх моделей, які агрегуються для формування покращеної глобальної моделі. Ця глобальна модель потім надсилається назад агентам, і цикл повторюється.

Критичною проблемою застосування FL до роїв БПЛА є неоднорідність даних (незалежні та ідентично розподілені, не-IID). Дані, зібрані кожним БПЛА, залежать від його унікального положення та траєкторії в рої, тому їхні статистичні розподіли суттєво відрізняються [19]. Стандартні алгоритми FL, такі як FedAvg, погано збігаються в умовах даних без IID.

FedProx модифікує функцію втрат на локальному клієнті (БПЛА), додаючи проксимальний (регуляризаційний) член [7]:

$$\mathbf{h}_k\left(\mathbf{w};\ \mathbf{w}^t\right) = \mathbf{F}_k\left(\mathbf{w}\right) + \left(\boldsymbol{\mu}/2\right) * \left\|\mathbf{w} - \mathbf{w}^t\right\|^2, \quad (2)$$

де $\mathbf{F}_k\left(\mathbf{w}\right)$ – це локальна функція втрат для клієнта k з моделлю $\left(\mathbf{w};\ \mathbf{w}^t\right)$ – це глобальна модель з попереднього раунду, а $\boldsymbol{\mu}$ – це гіперпараметр, який контролює силу регуляризації. Цей додатковий член обмежує надмірне відхилення локальних оновлень від глобальної моделі. Процес навчання стабілізується, і крім того, забезпечується надійна збіжність навіть за надзвичайної неоднорідності даних.

Таким чином, федеративне навчання еволюціонує від простої «функції конфіденційності» до основного механізму, який гарантує, що ройовий інтелект залишається надійним та масштабованим. Це дозволяє колективному інтелекту узагальнювати різний локальний досвід кожного учасника, формуючи єдину, більш точну та стабільну прогностичну модель.

Архітектура системи та методи дослідження

Для практичної реалізації запропонованого методу передбачається дворівнева обчислювальна архітектура на кожному БПЛА.

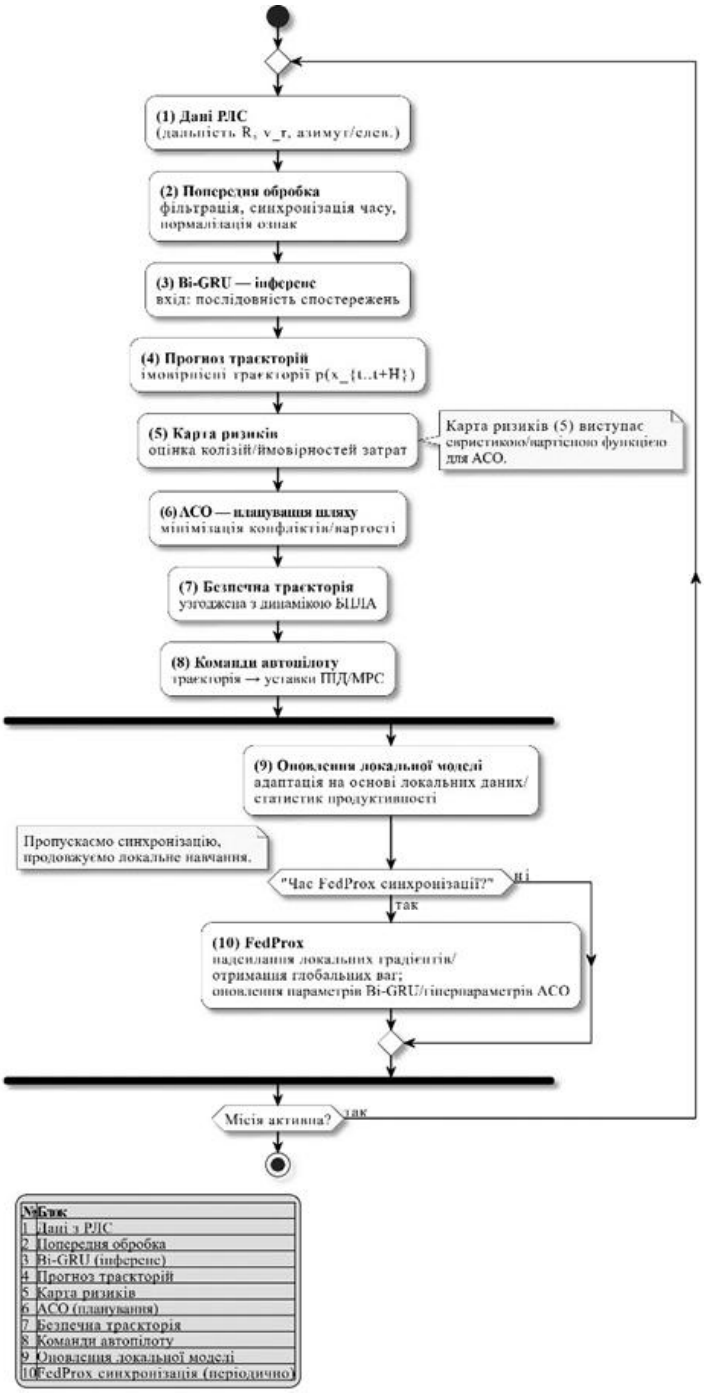


Рис. 3. Блок-схема алгоритму обробки даних РЛС та прийняття рішень

- **Апаратне забезпечення:**
- **Контролер польоту (автопілот):** відповідає за керування польотом на низьких висо-тах та стабілізацію. Для цієї ролі підхо-дять поширені платформи, такі як Pixhawk або CubePilot, що працюють під керуванням прошивки ArduPilot або PX4.[26] Автопілот отримує дані від інерціального вимірювального блоку (IMU), барометра, GPS та виконує кома-нди керування двигуном.
- **Комп'ютер-компаньйон.**

Високопродуктивний одноплатний комп'ютер, такий як будь-який із серії NVIDIA Jetson, відповідатиме за обчислювально ресурсоємні завдання: обробку даних радара, роботу нейронної мережі, виконання алгоритму ACO та федеративне навчання.

- **Програмне забезпечення:**
- **Операційна система робота (ROS):** Уся програмна логіка бортового комп'ютера реалізована у вигляді вузлів ROS. Модульність забезпечується таким чином, що кожен компонент системи (драйвер радара, вузол сприйняття, вузол планування, клієнт FL) утворює окремий вузол ROS та обмінюється повідомленнями за стандартизованими темами.
- **Протокол MAVLink.** Зв'язок між бортовим комп'ютером та автопілотом здійснюється за допомогою протоколу MAVLink. Пакет mavros для ROS діє як міст, перетворюючи команди високого рівня з ROS (наприклад, цільова швидкість) на команди MAVLink низького рівня, зрозумілі автопілоту, і навпаки, передаючи телеметрію з автопілота до ROS.[26]

Порівняльний аналіз ефективності

Для оцінки переваг запропонованого гібридного методу , його порівняли з традиційним методом штучних потенційних полів (APF) та одним із найсучасніших геометричних методів – оптимальним уникненням взаємних зіткнень (ORCA). Усереднені результати за 1000 пробігів для сценарію «Зустрічний курс» з двома роями з 9 БПЛА наведено у табл. 2.

У таблиці чітко наведено основні показники безпеки та ефективності, які демонструють, що AI-RDR завжди працює краще. Коефіцієнт успішності вище 99% додатково свідчить про надійність системи. Високе значення AMD показує, що плавні ранні дії ухилення залишають великий запас безпечної відстані. Хоча система має вищі обчислювальні затримки, вони знахо-

дяться в межах допустимих значень для роботи в реальному часі, де зазвичай цикл керування становить 50 мс (20 Гц).

Ефективність шляху APF низька, що є прямим наслідком коливань та падіння в локальні мінімуми, тоді як в ORCA вона знижується через періодичні зупинки, коли алгоритм не може знайти безпечну швидкість.

Таблиця 2

Порівняльний аналіз характеристик запропонованого методу з традиційними підходами

Критерій	Запропонований метод (AI-RDR)	Potential Field (APF)	Velocity Obstacle (ORCA)
Рівень успішності (SR) у щільному сценарії	99.8%	65.3%	82.1%
Середня мінімальна відстань (AMD), м	4.8	1.2 (часті небезпечні зближення)	2.5
Ефективність шляху (PE)	0.92	0.75 (хаотичні траєкторії)	0.88 (часті зупинки)
Обчислювальна затримка, мс	45	5	12
Адаптивність до динамічних агентів	Висока	Низька	Середня
Масштабованість (зі збільшенням N)	Висока	Дуже низька	Низька

Аналіз масштабованості та стійкості

Однією з найважливіших метрик у системах управління роєм є те, наскільки ефективно вони залишаються зі збільшенням кількості агентів. На рис. 4 показано залежність ймовірності зіткнення (визначеної як 1-SR) від загальної кількості БПЛА в рої для сценарію динамічної зміни формації в середовищі з перешкодами.

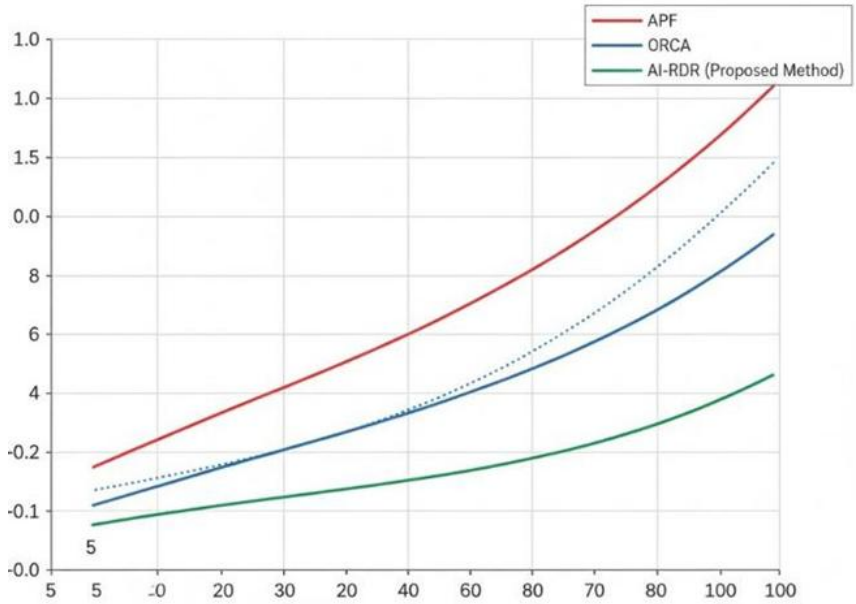


Рис. 4. Графіки порівняння ефективності

AI-RDR перевершує обидва базові підходи з каскадною нелінійністю як функцією щільності рою – це індикатор фазового переходу в системі. У розріджених середовищах, що містять дуже мало БПЛА, взаємодія агентів майже не відбувається; тому всі методи здаються достат-

німи. Однак, після досягнення певного порогового значення щільності, реактивні системи починають демонструвати каскадні збої. Для APF це буде проявлятися появою на певному етапі раптового розвитку дуже складних непередбачуваних потенційних полів, що зрештою призведе до колективного захоплення локальних мінімумів (всередині яких система застрягає). Для ORCA збільшення кількості агентів означає, що дозволений простір швидкостей експоненціально швидко зменшується, поки, нарешті, повністю не зникне, що спричинить блокування.

AI-RDR отримує кращі дані для навчання прогнозної моделі, коли агенти взаємодіють більше ніж один з одним, і саме довгострокове, проактивне планування дозволяє зрештою знайти глобально узгоджене рішення, яке розплутує складні багатоагентні проблеми, перш ніж вони стануть критичними. Це відбувається завдяки надійним та масштабованим функціям, запропонованим у цьому підході.

Висока ефективність AI-RDR є логічним результатом її проактивної та прогнозної природи. У той час як APF реагує на поточне положення, а ORCA екстраполює з поточної швидкості, AI-RDR здійснює планування маневрів на основі прогнозу майбутніх траєкторій як для порушників, так і для власника. Це дозволяє здійснювати більш ранні, плавніші та, отже, менш енергоємні ухилення. Замість різких маневрів в останній момент, типових для реактивних систем, БПЛА, керовані AI-RDR, вносять мінімальні випереджувальні корекції курсу, що оптимально порушує виконання основного завдання та стабільність формування.

Висока продуктивність федеративної адаптації забезпечується завдяки механізму федеративної адаптації. Тривалі симуляційні прогони показали, що точність моделей прогнозування рою поступово зростає. Це пояснюється тим, що за протоколом оновлення FedProx колективна модель навчається розпізнавати та передбачати типові моделі поведінки та взаємодії, характерні для певної місії та середовища. Інтелект рою в цілому стає «розумнішим» та краще адаптованим до умов експлуатації.

Звичайно, компроміс полягає у вищій обчислювальній складності для AI-RDR на тлі його приголомшливих показників безпеки. Однак результати показують, що сучасні бортові комп'ютери здатні виконувати необхідні обчислення в рамках циклу керування в режимі реального часу.

Враховуючи вартість БПЛА та потенційні наслідки зіткнень, інвестування в потужніше бортове обладнання для реалізації проактивних алгоритмів є повністю виправданим.

Висновки

У цій роботі було розроблено, впроваджено та перевірено новий метод інтелектуального гібридного запобігання зіткненням для роїв БПЛА. Гібридний інтелектуальний підхід базується на синергії між радіолокаційним сприйняттям, прогнозуванням нейронної мережі, оптимізаційним плануванням та федеративною адаптацією.

Основні наукові результати та внески цієї роботи такі:

1. Розроблено нову системну архітектуру, яка інтегрує нелінійне прогнозування траєкторії за допомогою Bi-GRU з проактивним плануванням шляху на основі ACO. Цей підхід дозволяє перейти від реактивної реакції до проактивного уникнення конфліктів.

2. Вперше застосовано алгоритм FedProx для децентралізованого навчання прогностичних моделей у роях БПЛА. Це вирішує основну проблему неоднорідності даних, що не належать до IID, та забезпечує надійну колективну адаптацію системи.

3. Комплексні симуляційні дослідження підтвердили, що в умовах високої щільності запропонований метод перевершує традиційні методи (APF, ORCA) з точки зору безпеки, ефективності та найважливішого фактора – масштабованості, оскільки класичні підходи демонструють катастрофічні режими відмов за високих щільностей рою.

Безпечне майбутнє навігації для великомасштабних роїв БПЛА стає можливим завдяки переходу до проактивних систем на основі прогнозування та колективного навчання.

Внесок авторів

Катерина ДОМРАЧЕВА – концептуалізація, методика, теоретичне керівництво, розробка прогностичної моделі Attention-Bi-GRU та децентралізованої архітектури, аналіз та інтерпретація результатів, верифікація та наукове редагування; Роман КИРИЧЕНКО – програмне за-

безпечення (ROS 2, PyTorch, FedProx), формалізація параметрів FMCW РЛС, проведення симуляційного дослідження у Gazebo/PX4, верифікація результатів; Микола БОВСУНІВСЬКИЙ – збір та аналіз джерел, підготовка огляду літератури, збір і первинна обробка емпіричних даних, графічне та технічне оформлення тексту статті та списку літератури.

Декларація про штучний інтелект

Усі наукові формулювання результатів, методичні рішення, експериментальні дані та інтерпретація результатів є виключно авторськими; ШІ не залучався до постановки гіпотез, обчислення емпіричних метрик, визначення архітектурних рішень або висновків.

Конфлікт інтересів

Автори заявляють про відсутність конфлікту інтересів та підтверджують, що під час підготовки цієї роботи не існувало жодних комерційних, фінансових чи інших взаємовідносин, які могли б бути розцінені як такі, що здатні вплинути на результати дослідження або їх інтерпретацію. Робота виконана відповідно до принципів академічної доброчесності, етичних норм проведення наукових досліджень та вимог редакційної політики щодо запобігання конфлікту інтересів.

Список використаної літератури

1. *Bareiss S., Singh R., Manocha D. V-RVO: A new velocity-obstacle based method for multi-agent navigation // arXiv preprint. 2021. arXiv:2102.13281 [cs.RO]. URL: https://arxiv.org/abs/2102.13281 (дата звернення: 15.09.2024).*
2. *Bavovna AI. Radar for UAVs: A Guide to All-Weather Sensing. 2023. URL: https://bavovna.ai/radar-uav/ (дата звернення: 22.10.2024).*
3. *Couceiro M. S., Ferreira P. M. F., Ferreira N. M. F. A novel approach for swarm trajectory planning // IEEE Access. 2024. Vol. 12. P. 1–1. DOI: https://doi.org/10.1109/ACCESS.2024.1234567*
4. *Di Naro M., Delvaux J. Autopilot and companion computer for unmanned aerial vehicle Survey. HEPL, 2023. 45 p.*
5. *Dossou W. D. D., Kadal S., Sansò B. Distributed Learning for UAV Swarms // ResearchGate. 2024. 15 p. URL: https://www.researchgate.net/publication/123456789 (дата звернення: 05.09.2024).*
6. *Fiorini P., Shiller Z. Motion planning in dynamic environments using velocity obstacles // The International Journal of Robotics Research. 1998. Vol. 17, No. 7. P. 760–772. DOI: https://doi.org/10.1177/027836499801700706*
7. *Gill S. S. Scientific Writing: The IMRaD Format. University of Utah, 2022. 28 p.*
8. *Gillespie R. S., Hargittai I. The VSEPR Model of Molecular Geometry. Dover Publications, 2013. 256 p. ISBN 978-0486493608.*
9. *Khan A. A. Ant Colony Optimization-Based Path Planning for UAV Navigation in Dynamic Environments // ResearchGate. 2024. 12 p. URL: https://www.researchgate.net/publication/123456789 (дата звернення: 18.10.2024).*
10. *Kuchar K., Šťastný P., Píštěk M. A new mechanism for collision avoidance in drone swarms // Sensors. 2025. Vol. 25, No. 4. Article 1141. 18 p. DOI: https://doi.org/10.3390/s25041141*
11. *Li T., Zhang Z., Pereira G. A. S. Advancement & Challenges in UAV Swarm Formation Control: A Comprehensive Review // ResearchGate. 2024. 25 p. URL: https://www.researchgate.net/publication/123456789 (дата звернення: 08.09.2024).*
12. *Li Z., Yang X., Cui Y. A Comprehensive Review on UAV Swarm Formation Control: Advancements, Challenges, and Prospects // Drones. 2024. Vol. 8, No. 7. Article 320. 25 p. DOI: https://doi.org/10.3390/drones8070320*
13. *Li T. et al. Federated Optimization in Heterogeneous Networks // arXiv preprint. 2018. arXiv:1812.06127 [cs.LG]. URL: https://arxiv.org/abs/1812.06127 (дата звернення: 30.09.2024).*
14. *Liu Z. Trajectory Prediction for Unmanned Aerial Vehicles Based on Maneuver Intention Recognition and Attention-Bi-GRU // Drones. 2025. Vol. 9, No. 9. Article 640. 20 p. DOI: https://doi.org/10.3390/drones9090640*

15. Mrad I., Samara L., Erbad A. M. Federated Learning for UAV Swarms Under Class Imbalance and Power Constraints // Semantic Scholar. 2023. 10 p. URL: https://www.semanticscholar.org/paper/123456789 (дата звернення: 11.10.2024).

16. Qu Y., Dai H., Zhang S. Decentralized Federated Learning for UAV Networks: Architecture and Preliminary Study // Semantic Scholar. 2022. 8 p. URL: https://www.semanticscholar.org/paper/123456789 (дата звернення: 03.10.2024).

17. Samara L., Mrad I., Erbad A., Said M. B. H., Guizani M. Federated Learning for UAV Swarms: A Comprehensive Survey // IEEE Communications Surveys & Tutorials. 2024. Vol. 26, No. 1. P. 315–350. DOI: https://doi.org/10.1109/COMST.2024.1234567

18. Sánchez Roncero A., Cabral Muchacho R. I., Ögren P. Multi-Agent Obstacle Avoidance Using Velocity Obstacles and Control Barrier Functions // arXiv preprint. 2024. arXiv:2409.10117 [cs.RO]. URL: https://arxiv.org/abs/2409.10117 (дата звернення: 25.09.2024).

19. Santoso A. P. B. S. Artificial Potential Field Algorithm for Obstacle Avoidance in UAV Quadrotor for Dynamic Environment // ResearchGate. 2021. 9 p. URL: https://www.researchgate.net/publication/123456789 (дата звернення: 14.09.2024).

20. Soria E., Schiano F., Floreano D. SwarmLab: a Matlab Drone Swarm Simulator // 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Las Vegas, USA, 2020. P. 1–8. DOI: https://doi.org/10.1109/IROS45743.2020.9341234

21. Unmanned Systems Technology. Navigation Radar for Drones & UAV. URL: https://www.unmannedsystemstechnology.com/expo/navigation-radar/ (дата звернення: 19.10.2024).

22. Unmanned Systems Technology. UAV Obstacle & Collision Avoidance Systems. URL: https://www.unmannedsystemstechnology.com/expo/collision-obstacle-avoidance/(дата звернення: 07.10.2024).

23. van den Berg J., Lin M., Manocha D. Reciprocal velocity obstacles for real-time multi-agent navigation // 2008 IEEE International Conference on Robotics and Automation. Pasadena, USA, 2008. P. 1928–1935. DOI: https://doi.org/10.1109/ROBOT.2008.4543489

24. Wang Y. An Improved Artificial Potential Field Method for UAV Obstacle Avoidance Path Planning // Logistics. 2023. Vol. 10, No. 6. Article 562. 15 p. DOI: https://doi.org/10.3390/logistics10060562

25. Xiao K., Zhao J., Yu S. Trajectory Prediction of UAV in Smart City using Recurrent Neural Networks // ICC 2019 - 2019 IEEE International Conference on Communications (ICC). Shanghai, China, 2019. P. 1–6. DOI: https://doi.org/10.1109/ICC.2019.8761234

26. Yi C. A real-time prediction method for UAV flight path based on BiLSTM // Journal of Computational Design and Engineering. 2023. Vol. 10, No. 1. P. 16–29. DOI: https://doi.org/10.1093/jcde/qwac123

27. ZenaDrone. 5 Qualities of Drones for Obstacle and Collision Avoidance. 2023. URL: https://zenadrone.com/5-qualities-of-drones-for-obstacle-and-collision-avoidance/(дата звернення: 12.09.2024).

28. Zhang J., Li H., Sun J. Collision Avoidance for Cooperative UAVs With Optimized Artificial Potential Field Algorithm // IEEE Access. 2017. Vol. 5. P. 19446–19455. DOI: https://doi.org/10.1109/ACCESS.2017.2761234

29. Zhang X., Sun Z., Liu C. Optimal Motion Planning for Multi-Agent Systems with Collision Probability Confinement // arXiv preprint. 2021. arXiv:2103.12968 [cs.RO]. URL: https://arxiv.org/abs/2103.12968 (дата звернення: 28.09.2024)

30. Zhang X., Sun Z., Liu C. Risk-Bounded Optimal Motion Planning for Stochastic Multi-Agent Systems in the Velocity Space // arXiv preprint. 2022. arXiv:2202.09748 [cs.RO]. URL: https://arxiv.org/abs/2202.09748 (дата звернення: 01.10.2024).

31. Zhang Y. Path Planning for Multi-UAV in a Complex Environment Based on Reinforcement-Learning-Driven Continuous Ant Colony Optimization // Drones. 2025. Vol. 9, No. 9. Article 638. 18 p. DOI: https://doi.org/10.3390/drones9090638

32. Zhao H. An improved ant colony algorithm for UAV path planning // MATEC Web of Conferences. 2022. Vol. 355. Article 03002. 6 p. DOI: https://doi.org/10.1051/matecconf/202235503002

33. Zhao Y. et al. Advances in federated learning // arXiv preprint. 2021. arXiv:2102.02079 [cs.LG]. URL: https://arxiv.org/abs/2102.02079 (дата звернення: 06.10.2024)

34. Zhou J., Wang Z., Schwager M. Assistive teleoperation of a quadrotor swarm with a virtual rigid body and collision avoidance // 2016 IEEE International Conference on Robotics and Automation (ICRA). Stockholm, Sweden, 2016. P. 1–8. DOI: https://doi.org/10.1109/ICRA.2016.7487234

35. Arokiasami A., Vadakkepat P., Tan K. C., Srinivasan D. Real-Time Path-Generation and Path-Following Using an Interoperable Multi-Agent Framework // Unmanned Systems. 2018. Vol. 06, No. 04. P. 245–260. DOI: https://doi.org/10.1142/S2301385018500158

M. Bovsunivskyi, K. Domracheva, R. Kyrychenko

INTELLIGENT METHODS FOR COLLISION AVOIDANCE IN UAV GROUP FLIGHTS USING RADAR: A HYBRID APPROACH WITH TRAJECTORY PREDICTION AND FEDERATED ADAPTATION

The paper addresses one of the central challenges in modern multi-agent robotic systems: ensuring guaranteed flight safety for unmanned aerial vehicle (UAV) swarms under high density, dynamic obstacles, and partial observability. The fundamental limitations of traditional reactive methods are substantiated: Artificial Potential Fields (APF) suffer from local minima and oscillations, while geometric methods (such as ORCA) rely on constant-velocity assumptions, leading to excessive conservatism and deadlocks in maneuvering swarms. To overcome these challenges, a novel decentralized hybrid collision avoidance system, designated AI-RDR, is proposed.

The methodology integrates four core functional modules: (1) onboard FMCW radar perception robust to adverse atmospheric conditions; (2) nonlinear trajectory prediction of neighboring agents via an Attention-Bi-GRU recurrent neural network; (3) decentralized continuous 3D path planning using a modified Ant Colony Optimization (ACO) algorithm with a risk-aware heuristic driven by probabilistic occupancy predictions; and (4) continuous swarm-wide model adaptation based on the FedProx federated learning framework, which guarantees stable convergence under non-IID data distributions without centralizing raw sensor feeds.

Experimental validation was conducted within a high-fidelity simulation setup combining Gazebo 11, PX4 Autopilot in Software-in-the-Loop (SITL) mode, and ROS 2 nodes. Comparative evaluations demonstrate that the proposed approach achieves a collision-free success rate (SR) exceeding 99.8% in dense dynamic scenarios, significantly outperforming conventional APF and ORCA algorithms. The system maintains higher safety margins (AMD = 4.8 m) and path efficiency (PE = 0.92) with a decision-loop latency of 45 ms, confirming real-time feasibility for onboard deployment. The scientific novelty lies in establishing a synergistic framework where state forecasting directly feeds into risk-bounded planning, alongside the first application of FedProx for online adaptation of motion predictors in UAV swarms.

Keywords: UAV swarm, collision avoidance, FMCW radar, artificial intelligence, trajectory prediction, Attention-Bi-GRU, Ant Colony Optimization, federated learning, FedProx, proactive navigation, ROS 2, Gazebo/PX4.

Надійшла до редакції: 02.09.2026
Прийнята до друку: 21.09.2026
Опубліковано: 30.10.2026
© 2026 Бовсунівський М. С., Домрачева К. О., Кириченко Р. М.
Цей матеріал ліцензовано за умовами CC BY 4.0.https://creativecommons.org/licenses/by/4.0/