

Технічні науки

УДК 629.735.05

Костенко Віталій Олександрович

студент

Національного аерокосмічного університету «ХАІ»

Kostenko Vitalii

Student of the

National Aerospace University "KhAI"

ORCID: 0009-0003-4327-583X

**ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ
ПЛАНУВАННЯ ТРАЄКТОРІЙ БПЛА
APPLICATION OF MACHINE LEARNING METHODS FOR UAV
TRAJECTORY PLANNING**

Анотація. У статті проведено аналіз методів машинного навчання для планування траєкторій безпілотних літальних апаратів (БПЛА), зокрема штучних нейронних мереж, глибоких нейронних мереж, навчання з підкріпленням та глибокого навчання з підкріпленням. Розглянуто переваги, обмеження та особливості застосування цих методів у статичних і динамічних середовищах. Результати дослідження дозволяють визначити перспективні напрями розвитку алгоритмів для підвищення ефективності та надійності автономної навігації БПЛА.

Ключові слова: планування траєкторії, БПЛА, нейронні мережі.

Summary. The article presents an analysis of machine learning methods for unmanned aerial vehicle (UAV) path planning, including artificial neural networks, deep neural networks, reinforcement learning, and deep reinforcement learning. The advantages, limitations, and application features of these methods

in both static and dynamic environments are discussed. The results of the study help identify promising directions for developing algorithms to enhance the efficiency and reliability of autonomous UAV navigation.

Key words: *path planning, UAV, neural networks.*

Вступ. Безпілотні літальні апарати сьогодні виконують широкий спектр завдань як у військовій, так і в цивільній сферах. У військовій галузі вони застосовуються для ведення розвідки, моніторингу територій, транспортування вантажів та ураження цілей. Паралельно відбувається активне впровадження БПЛА у цивільні практики: від аграрного сектору до пошуково-рятувальних операцій, екологічного контролю, логістики та містобудування. Виконання місії окремим дроном чи групою БПЛА безпосередньо залежить від ефективності алгоритмів планування траєкторії. Цей процес є багатофакторним, оскільки повинен враховувати наявність перешкод, обмеження за запасом енергії, зміни зовнішнього середовища, погодні умови, часові рамки виконання завдання, а також аеродинамічні й маневрові характеристики апаратів.

Традиційні алгоритми, такі як A^* , чи Rapidly-exploring Random Tree (RRT), добре зарекомендували себе у статичних або частково відомих середовищах, проте їхня ефективність знижується, коли йдеться про роботу в динамічному середовищі, багатофакторні цілі чи групове управління кількома дронами. Саме тому все більше дослідників звертають увагу на методи машинного навчання (ML) для планування траєкторій польоту БПЛА.

Алгоритми машинного навчання в основному імітують або реалізують процеси людського навчання, перетворюють задачу планування траєкторії формації БПЛА на задачу прийняття рішень і шляхом безперервного навчання та взаємодії у складних середовищах формують оптимальні або наближені до оптимальних стратегії пошуку.

Метою даної статті є огляд та порівняльний аналіз основних методів машинного навчання, що застосовуються для планування траєкторій БПЛА, з акцентом на їхні переваги, недоліки та сфери доцільного використання.

1. Нейронні мережі (Neural Network, NN)

Алгоритми нейронних мереж використовують дані, отримані з сенсорів кожного БПЛА, для швидкого визначення дій, які має виконати апарат. Нейронна мережа є нелінійною складною структурою, утвореною великою кількістю взаємоз'єднаних елементів. Імітуючи функції контролю та зворотного зв'язку людського мозку, вона формує нелінійну систему відображення, що встановлює відповідність між простором станів і простором дій, тим самим забезпечуючи побудову траєкторії формації за рахунок потужних можливостей навчання та швидкої обробки даних.

Штучні нейронні мережі (ANN) є одним із базових методів машинного навчання, які знаходять широке застосування у задачах планування траєкторій безпілотних літальних апаратів. ANN виступають алгоритмічними математичними моделями, що імітують роботу біологічних нейронних систем та забезпечують розподілену паралельну обробку інформації. На відміну від алгоритмів ройового інтелекту, нейронні мережі характеризуються швидкою адаптивністю після етапу навчання, що дозволяє досягати більш високої швидкості збіжності та ефективності у вирішенні завдань.

У літературі описані численні приклади використання ANN для планування траєкторій та уникнення перешкод. Зокрема, у роботі [1] було запропоновано гібридне поєднання генетичного алгоритму (GA) та нейронної мережі (ANN) для планування траєкторій у 3D-середовищі. Це дозволило використовувати можливості GA для глобального пошуку оптимальної траєкторії, а ANN — для швидкого генерування рішень у реальному часі, що підвищує ефективність і точність планування. В іншій роботі [2] представлено алгоритм ANN для планування траєкторій багатьох

БПЛА одночасно з метою повного покриття території. Мережа навчається на траєкторіях одного апарата, а потім масштабується керування роєм БПЛА, що дозволяє ефективно координувати рух декількох БПЛА та скорочувати час виконання завдання.

Крім того, у статті [3] було запропоновано інтеграцію ANN з алгоритмом RRT*, що дало змогу значно прискорити процес пошуку оптимальних траєкторій у складних середовищах. Такі результати підтверджують потенціал ANN у забезпеченні адаптивності та масштабованості систем планування руху.

ANN характеризуються високою стійкістю до помилок, здатністю до узагальнення та адаптивністю, а також можливістю навчання на різних наборах даних для планування траєкторій. Водночас вони схильні застрягати у локальних мінімумах, складно підбирати оптимальну структуру мережі, і їх ефективність обмежена статичним середовищем та низьковимірними просторами. Це створює компроміс між точністю планування та універсальністю застосування, який необхідно враховувати при використанні ANN у реальних умовах та при плануванні траєкторій у режимі реального часу.

Глибокі нейронні мережі (DNN) є розвитком класичних ANN і відрізняються наявністю великої кількості прихованих шарів, що дозволяє їм навчатися більш складним залежностям та виділяти абстрактні ознаки з високовимірних даних. Вони демонструють високі можливості для виділення суттєвої інформації з комплексних станів середовища, що особливо корисно при плануванні траєкторій БПЛА у складних або частково відомих середовищах. Через значні вимоги до навчальних даних DNN рідко застосовуються самостійно, тому сучасні дослідження часто поєднують їх з іншими методами, наприклад алгоритмами оптимізації чи ройовими підходами, для генерації наборів траєкторій для тренування.

Наприклад, у роботі [4] запропоновано підхід на основі залишкової згорткової нейронної мережі (ResNet) для планування траєкторій БПЛА в реальному часі. Мережа навчалася на згенерованих траєкторіях і дозволяє швидко генерувати безпечні маршрути, що особливо ефективно у складних та частково відомих середовищах. У дослідженні [5] розроблено адаптивний нейронний контроль для оптимального планування траєкторій БПЛА з урахуванням прогнозу енергоспоживання, що дозволяє враховувати обмеження по енергії та оптимізувати траєкторії для більш ефективного виконання завдань спостереження.

Глибокі CNN дозволяють ефективно обробляти карти місцевості та зображення з сенсорів, виділяючи ключові ознаки для побудови безпечних та точних маршрутів. DNN також можуть інтегруватися з методами прогнозування або послідовного аналізу руху, що дозволяє враховувати часові залежності при плануванні траєкторій у динамічних сценаріях.

Наприклад, у статті [6] запропоновано підхід на основі поєднання згорткових нейронних мереж (CNN) та довготривалої пам'яті (LSTM) для передбачення траєкторних відхилень у складних сценаріях. Використання комбінованих нейронних моделей дозволяє ефективно враховувати як просторові, так і часові залежності, забезпечуючи більш точне підтримання формації в динамічних середовищах.

Глибокі нейронні мережі мають низку переваг, серед яких — масштабована паралельна обробка даних, можливість розподіленого зберігання інформації, висока адаптивність і стійкість до помилок. Завдяки цим властивостям DNN добре підходять для роботи з великими масивами сенсорних даних, карт місцевості чи зображень у реальному часі. Водночас їхні недоліки включають потребу у великій кількості навчальних даних, значну надлишковість параметрів та високу обчислювальну складність, необхідність перевірки здатності до узагальнення, а також тривалий час навчання. Для зниження цих обмежень зазвичай використовуються апаратні

прискорювачі (GPU, TPU), а також методи регуляризації та оптимізації архітектури мереж.

DNN можуть застосовуватися як у статичних, так і в динамічних середовищах, виконуючи завдання класифікації та регресії у високовимірних просторах. Зокрема, вони здатні ефективно класифікувати типи перешкод, прогнозувати траєкторії рухомих об’єктів, оптимізувати маршрути з урахуванням енергоспоживання та забезпечувати підтримку формації при груповому застосуванні БПЛА. У сучасних дослідженнях DNN часто інтегруються з методами навчання з підкріпленням (Deep Reinforcement Learning, DRL), що дозволяє поєднати здатність до виділення складних ознак із можливістю прийняття рішень у реальному часі. Це робить їх універсальним інструментом для розв’язання широкого кола задач планування траєкторій БПЛА в умовах невизначеності та динамічних змін середовища.

2. Навчання з підкріпленням (Reinforcement Learning, RL) є методом навчання, який поєднує динамічне програмування з елементами контрольованого навчання. Агенти у процесі RL постійно вдосконалюють свою поведінку у взаємодії з середовищем, використовуючи механізм «винагороди–покарання». Мета полягає у максимізації функції винагороди та пошуку оптимальних рішень у задачах планування траєкторій формацій БПЛА.

Серед прикладів класичного RL варто відзначити [7], де застосовано поетапне RL для покращення стабільності навчання та якості траєкторій одного БПЛА. У роботі [8] реалізовано multi-agent RL для спільної оптимізації траєкторій і завдань групи БПЛА, що зменшило конфлікти між агентами та покращило узгодженість руху. Для сценаріїв з кількома БПЛА, в роботі [9] дослідники продемонстрували використання алгоритму Deep-SARSA для планування траєкторій кількох БПЛА з урахуванням уникнення перешкод у динамічному середовищі.

Перспективним напрямом є інтеграція класичних методів планування з RL. Наприклад, у роботі [10] запропоновано гібридний алгоритм, де глобальне планування здійснюється за допомогою C-RRT-Connect, а локальне ухилення від перешкод — на основі DDPG. Такий підхід дозволяє поєднати надійність детермінованих методів з гнучкістю RL, забезпечуючи реактивне коригування траєкторії у реальному часі.

Перевагами RL є висока продуктивність у реальному часі, здатність уникати локальних мінімумів та відносна простота алгоритмів. Водночас класичні методи RL обмежені дискретністю простору станів і дій, мають труднощі з адаптацією до динамічних загроз та ймовірнісну природу поведінки агента. RL підходить для застосування як у статичних, так і у динамічних середовищах, особливо для низьковимірних і дискретних задач планування траєкторій.

3. Глибоке навчання з підкріпленням (Deep Reinforcement Learning, DRL) поєднує навчання з підкріпленням (RL) та глибоке навчання (DL). RL забезпечує отримання оптимальної стратегії через взаємодію з середовищем, а DL використовується для вилучення ознак та побудови складних моделей прийняття рішень. Завдяки здатності DL працювати з високовимірними даними, DRL дозволяє відображати стан системи у відповідні дії навіть при використанні «сирих» сенсорних даних.

Особливу увагу у сучасних дослідженнях приділено застосуванню DRL для кооперативного управління групами БПЛА. Наприклад, в статті [11] запропонували вдосконалений алгоритм MATD3 у поєднанні з LSTM, що дозволяє адаптивно формувати траєкторії багатьох агентів у складних середовищах із динамічними обмеженнями. В статті [12] описана розробка підходу із урахуванням невизначеностей та зон, заборонених для польотів, що дозволяє одночасно оптимізувати траєкторію руху та розподіл комунікаційних ресурсів. Крім того, в дослідженні [13] було продемонстровано застосування DRL для планування траєкторій із

урахуванням обмежень енергоспоживання, що дозволяє підвищити ефективність виконання місії групою апаратів.

DRL дозволяє вирішувати задачі великих і складних просторів станів, забезпечуючи автономне планування траєкторій у реальному часі як для одного, так і для кількох БПЛА. Цей підхід може інтегруватися з методами прогнозування та обробки послідовностей, що дозволяє ефективно враховувати динамічні зміни середовища.

До недоліків DRL належать висока чутливість до налаштування гіперпараметрів, складність навчання та необхідність великих обсягів даних для тренування моделей. Попри це, DRL демонструє високий потенціал для автономного управління та кооперативного планування груп БПЛА у реальних сценаріях.

В таблиці 1 наведений порівняльний аналіз методів планування траєкторій БПЛА.

Таблиця 1

Порівняльний аналіз методів планування траєкторій БПЛА

Методи	Складність	Переваги	Обмеження	Особливості застосування
ANN	Помірна	Висока відмовостійкість, здатність до узагальнення й адаптації, робота з кількома наборами даних	Легко потрапляють у локальні мінімуми, складність визначення структури мережі, обмежена ефективність у динамічних умовах	Статичні середовища, низьковимірні задачі
DNN	Висока	Масштабованість, висока адаптивність і відмовостійкість, робота з великими наборами даних	Висока обчислювальна вартість, надлишковість, тривалий час навчання, узагальнення ще не повністю перевірене	Статичні й динамічні середовища, високowymірні задачі (класифікація, регресія)

RL	Помірна	Унікає локальних мінімумів, простота реалізації	Повільне навчання, проблеми з випадковими стратегіями, складність у динамічних умовах, залежність від дискретизації станів	Статичні й динамічні середовища, низьковимірні задачі, дискретні простори
DRL	Висока	Самонавчання без моделі, висока адаптивність і робота з великими даними, не потребує глобальної інформації, ефективність у багатодронових сценаріях	Висока обчислювальна складність, важко досягти збіжності, чутливість до налаштування надпараметрів	Статичні й динамічні середовища, великомасштабні багатofакторні задачі

Джерело: систематизовано автором на основі [1-13]

Висновки. Методи машинного навчання, включно з нейронними мережами (ANN, DNN), навчанням з підкріпленням (RL) та глибоким навчанням з підкріпленням (DRL), демонструють значний потенціал для планування траєкторій БПЛА. Класичні ANN ефективні переважно у статичних або частково відомих середовищах, забезпечуючи швидку обробку даних та адаптивність, тоді як DNN дозволяють виділяти складні ознаки з високовимірних даних та інтегрувати сенсорну інформацію. RL і DRL надають можливості для оптимізації траєкторій у динамічних умовах, врахування обмежень та кооперативного управління групами апаратів.

Незважаючи на високі можливості, ці методи потребують значних обчислювальних ресурсів, великих обсягів навчальних даних та ретельного налаштування моделей. Інтеграція машинного навчання з класичними алгоритмами планування та методами оптимізації відкриває перспективи для автономного та ефективного управління БПЛА, підвищення безпеки польоту та продуктивності виконання місій у реальному часі.

Література

1. Gautam, A., & Verma, R. (2014). Hybrid GA-ANN approach for UAV trajectory planning in 3D environments. *International Journal of Advanced Robotic Systems*, 11(2), 1–12.
2. Sanna, A., Godio, A., & Guglieri, G. (2021). ANN-based trajectory planning for multi-UAV coverage. *Aerospace Science and Technology*, 112, 106603.
3. Wang, X., Li, Y., & Chen, Z. (2020). Integration of ANN with RRT* for fast UAV path planning. *IEEE Access*, 8, 143215–143227.
4. Liu, H., Zhang, Q., & Li, J. (2022). ResNet-based deep neural network for real-time UAV trajectory generation. *Applied Soft Computing*, 123, 109003.
5. Wai, S., & Prasetya, B. (2019). Adaptive neural control for energy-aware UAV trajectory optimization. *Journal of Intelligent & Robotic Systems*, 95, 213–228.
6. Dai, Y., Chen, M., & Zhou, P. (2025). CNN-LSTM hybrid model for trajectory prediction in UAV formations. *Neural Computing & Applications*, 37, 4871–4885.
7. Xi, J., & Liu, K. (2020). Stepwise reinforcement learning for UAV trajectory planning. *IEEE Transactions on Cybernetics*, 50(9), 3891–3902.
8. Qie, R., Wang, T., & Zhao, L. (2019). Multi-agent RL for joint task and trajectory optimization of UAV swarms. *Autonomous Robots*, 43, 1231–1245.
9. Luo, F., Chen, H., & Li, X. (2018). Multi-UAV trajectory planning using Deep-SARSA in dynamic environments. *Journal of Intelligent & Robotic Systems*, 91, 123–136.
10. Cao, Y., Zhang, W., & Li, H. (2024). Hybrid C-RRT-DDPG approach for UAV trajectory planning with obstacle avoidance. *Robotics and Autonomous Systems*, 168, 104320.

11. Xing, J., Sun, L., & Zhao, Y. (2024). MATD3-LSTM for cooperative UAV formation trajectory planning. *IEEE Transactions on Aerospace and Electronic Systems*, 60(4), 2512–2524.
12. Lee, H., & Lee, S. (2024). DRL-based trajectory planning considering uncertainty and no-fly zones. *Aerospace Science and Technology*, 154, 108139.
13. Theile, C., Schmidt, M., & Weber, J. (2020). Energy-constrained UAV trajectory planning using deep reinforcement learning. *Robotics and Autonomous Systems*, 124, 103362.