

Perspective privind controlul UAS în medii acvatic, bazate pe învățare automată

Perspectives Regarding UAS Control in Aquatic Environments (Rivers and Streams) based on Machine Learning

Lt. Cosmin-Alin MIRCEA*

*Ministerul Apărării Naționale, România
e-mail: srg_cosminalin@yahoo.com

Abstract

În ultimii ani, integrarea inteligenței artificiale (AI) și a învățării automate (ML) în sistemele de vehicule aeriene fără pilot (UAS) a dus la o autonomie decizională sporită, în special în medii complexe și dinamice. Acest studiu propune un cadru inovator pentru operarea autonomă a UAV-urilor în scenarii acvatice, concentrându-se pe supravegherea continuă a unui vas în mișcare. Sistemul utilizează date de la mai mulți senzori pentru a permite unui UAV să rămână într-un perimetru definit în jurul ambarcațiunii, să mențină stabilitatea deasupra apei și să aterizeze automat pe o platformă mobilă atunci când este necesar (de exemplu, în caz de baterie descărcată sau interferențe). Arhitectura decizională se bazează pe algoritmi de învățare prin consolidare pentru controlul zborului și gestionarea înlocuirii dronelor. Contribuția acestui studiu constă în propunerea unui model inteligent și modular pentru coordonarea sistemelor multi-UAV pentru misiuni fluviale, cu aplicații directe în supraveghere, căutare și salvare și în monitorizarea mediului.

In recent years, the integration of artificial intelligence (AI) and machine learning (ML) in unmanned aerial systems (UAS) has led to increased decision-making autonomy, particularly in complex and dynamic environments. This study proposes an innovative framework for the autonomous operation of UAVs in aquatic scenarios, focusing on the continuous surveillance of a moving vessel. The system uses data from multiple sensors to allow a UAV to stay within a defined perimeter around the vessel, maintain stability above the water, and automatically land on a mobile platform when necessary (e.g., in case of low battery or interference). The decision-making architecture is based on reinforcement learning algorithms for flight control and drone replacement management. The contribution of this study is to propose an intelligent and modular model for the coordination of multi-UAV systems for river missions, with direct applications in surveillance, search and rescue, and environmental monitoring.

Cuvinte-cheie:

învățare automată; sisteme aeriene fără pilot (UAS); inteligență artificială; medii acvatice; senzori.

Keywords:

Machine Learning; Unmanned Aerial System (UAS); Artificial Intelligence; Aquatic Environments; Sensors.

Info articol

Primit: 14 august 2025; Evaluat: 1 septembrie 2025; Acceptat: 11 septembrie 2025; Disponibil online: 6 octombrie 2025

Citare: Mircea, C.A. 2025. „Perspective privind controlul UAS în medii acvatice bazate pe învățare automată”. *Buletinul Universității Naționale de Apărare „Carol I”*, 14(3): 7-24. <https://doi.org/10.53477/2065-8281-25-17>



© Editura Universității Naționale de Apărare „Carol I”

Articol cu acces deschis distribuit în conformitate cu termenii și condițiile licenței Creative Commons Attribution (CC BY-NC-SA)

Odată cu dezvoltarea inginerescă și tehnologică a diverselor echipamente sau dispozitive, vehiculele aeriene fără pilot (UAV – Unmanned Aerial Vehicles), prin valoarea lor, reprezintă capacități relevante pentru numeroase domenii și scopuri: agricultură, apărare, misiuni de căutare și salvare etc. Prin vizualizarea și cercetarea anumitor aspecte multidisciplinare, se pot identifica potențialele optimizări ale oricărui produs sau set de produse. Prin conectarea acestora într-o rețea, ele pot comunica eficient, rapid și interschimbabil, oferind astfel un instrument esențial și sigur pentru practicarea managementului decizional și desfășurarea cu succes a operațiunilor.

Operarea dronelor atât în medii maritime, cât și cele fluviale este dificilă, din cauza mișcării platformei (bărcii), instabilității semnalului, condițiilor meteorologice și limitărilor energetice. Problema este cum putem asigura prezența continuă a unei drone active în aer, deasupra unei bărci, menținând-o într-un perimetru definit, cu localizare și aterizare automată, precum și înlocuirea automată în diverse situații, pe baza inteligenței artificiale (Artificial Intelligence – AI) și a managementului decizional autonom. Pentru a aborda această situație, trebuie analizate următoarele aspecte, așa după cum se arată în figura de mai jos (Figura 1) și așa după cum menționează și autorii M. Hassanalian și A. Abdelkefi (Hassanalian și Abdelkefi 2017, 99-131).

Dronele pot fi utilizate în domeniile menționate mai sus, mai precis pentru supraveghere fluvială sau maritimă, în cazuri de pescuit ilegal, de contrabandă sau de securitate națională. Pentru misiunile de căutare și salvare pe mare, această soluție de continuitate, bazată pe învățare automată (Machine Learning – ML) poate fi esențială pentru salvarea vieților omenești. În plus, în scopuri de monitorizare și de protecție a mediului, acest sistem poate fi folosit pentru culegerea de date, precum temperatura și prezența poluanților, pe baza senzorilor integrați.

În cele din urmă, un astfel de sistem poate fi utilizat ca nod de releu între țărm și barcă, asigurând comunicarea dintre cele două stații într-un mod redundant.




Figura 1 Principalele obstacole privind controlul UAS în mediul acvatic

(Sursă: adaptată din https://static.wixstatic.com/media/bca94f_496a78a2fa3a4697a9cfc8eb4222ad5a~mv2.jpeg/v1/fill/w_748,h_606,al_c,q_85,usm_0.66_1.00_0.01,enc_avif,quality_auto/bca94f_496a78a2fa3a4697a9cfc8eb4222ad5a~mv2.jpeg)

Prin analiza literaturii de specialitate disponibile și prin concentrarea celor mai recente informații, acest studiu explorează aplicarea învățării automate și a inteligenței artificiale pentru îmbunătățirea controlului și autonomiei UAS-urilor în domeniul fluvial, cu accent îndeosebi asupra coordonării, toleranței la erori și continuității misiunii.

Lucrarea este structurată astfel: introducere, stadiul actual al cercetării (revizuirea literaturii), metodologie – cadrul și baza conceptuală –, rezultate și discuții – analiză teoretică și direcții viitoare –, și concluzii. Cercetarea va contribui la următorii pași către simulări practice, utilizând UAV-uri cu cost redus, configurabile atât software, cât și hardware, și capabile de învățare automată (ML).

1. Stadiul actual al cercetării

Analizând literatura de specialitate pe această temă, se observă că problema ridicată prezintă un interes major în rândul specialiștilor, mai ales dacă luăm în considerare evoluția spațiului geopolitic la nivel global, unde UAS sunt utilizate din ce în ce mai mult. În cadrul conflictelor actuale, s-a constatat faptul că dronele reprezintă un mijloc foarte eficient de folosit în luptă, substituind factorul uman. Din doctrina Network-Centric Warfare (NCW), a reieșit o nouă doctrină actuală, centrată pe drone, pe care armata ucraineană o implementează prin crearea de subunități luptătoare de nivel companie și chiar de unități de nivel batalion, cu specific în atacul cu drone, din cadrul brigăzilor de luptă (Samus 2024, 9).

L. Wu, C. Wang, P. Zhang și C. Wei (2022) oferă o analiză cuprinzătoare a modului în care învățarea prin întărire (*Reinforcement Learning – RL*) poate fi aplicată pentru îmbunătățirea coordonării UAV-urilor pe baza feedbackului corectiv, concentrându-se astfel pe îmbunătățirea aterizării autonome pe platforme mobile (Song 2022). Aspectele menționate sunt esențiale pentru coordonarea rețelei în medii acvatice, unde intervenția manuală este, de obicei, imposibilă. Metoda RL poate asigura confidențialitatea și poate reduce latența (Chellapandi și alții 2023, 3-6; Jung și alții 2024, 1-23; Negru și alții 2024, 1-23) – un aspect important în ceea ce privește securitatea UAS-urilor, precum și operarea acestora în medii ostile, unde pot apărea fluctuații de conexiune.

Un studiu care abordează provocările vizuale specifice mediului maritim (de exemplu, reflexiile apei) și mișcările neregulate ale țintelor demonstrează că rețelele neuronale convoluționale (*Convolutional Neural Networks – CNN*) pot fi utilizate de un roi de UAV-uri (*UAV swarm*) pentru a urmări cu succes anumite ținte (Zhao și alții 2024; 3-18; Maharjan și alții 2022, 1-24), în timp ce studiul ”A Survey on UAV-Aided Maritime Communications: Deployment Considerations, Applications, and Future Challenges” (Nomikos și alții 2023, 56-78) analizează utilizarea UAV-urilor ca noduri aeriene în comunicațiile maritime prin optimizarea traiectoriilor și prin folosirea ML pentru gestionarea resurselor și mutarea datelor stocate către marginea rețelei (*edge caching*). Acest lucru este foarte relevant pentru UAV-urile din medii ostile, unde conectivitatea necesită soluții adaptive, bazate pe învățare automată.

N.I. Sarkar și S. Gul (2023) au realizat o revizuire care acoperă peste 100 de lucrări privind rețelele autonome UAV bazate pe inteligență artificială, concentrându-se pe planificare, rutare, gestionarea resurselor și eficiența energetică. Ei au subliniat necesitatea optimizării acestor elemente prin ML, cu aplicare directă la scenarii acvaticice complexe.

Studii recente privind acțiunea dronelor pe cursurile de râu, precum ”*Synergistic Reinforcement and Imitation Learning for Vision-driven Autonomous Flight of UAV Along River*” (Wang, Li și Mahmoudian 2024), afirmă că îmbinarea RL cu învățarea prin imitație (*Imitation Learning – IL*) permite UAV-urilor să navigheze autonom de-a lungul râurilor, bazându-se pe viziune artificială, cu o viteză mai mare de învățare și o acuratețe sporită. Se sugerează, de asemenea, o metodă sinergică, ce combină IL și RL pentru navigarea UAV-urilor și evitarea obstacolelor în medii fluviale. Aceasta abordează dificultăți din medii parțial observabile, non-Markoviene, și îmbunătățește performanța și ratele de convergență prin utilizarea unui mediu de simulare antrenabil.

Malik Haris și Jin Hou prezintă o problemă reală, și anume detectarea obstacolelor și navigarea sigură, de această dată pentru vehicule terestre fără pilot (*Unmanned Ground Vehicles – UGVs*), în situații în care acestea trebuie să urmeze o rută prestabilită (Haris și Hou 2020, 1-22). Pe traseul pe care vehiculul trebuia să îl parcurgă, au fost amplasate obstacole periculoase, care ar fi pus în primejdie dispozitivul. Pentru implementarea eficientă a inteligenței artificiale care ia decizii sigure pe baza obstacolelor întâlnite, au fost analizate aspecte privind distanța, dimensiunea, aglomerarea, forma și unghiul volanului, lucrarea având ca scop îmbunătățirea abilităților de navigație ale vehiculelor autonome. Această lucrare are aplicabilitate pentru tema aleasă, deoarece obstacolele reprezintă un factor critic pe care inteligența artificială a dronei trebuie să îl detecteze și să îl evite.

Trecând în domeniul aerian, A. Antonopoulos, M.G. Lagoudakis și P. Partsinevelos descriu dezvoltarea și implementarea unui sistem integrat de navigație UAV care oferă localizare în timp real, folosind date optice, de adâncime și inerțiale, precum și Sistemul Global de Navigație prin Satelit (*Global Navigation Satellite System – GNSS*) (Antonopoulos, Lagoudakis și Partsinevelos 2022, 1-23). Pentru a facilita integrarea fără probleme în diverse sisteme și medii necunoscute, sistemul implementat este construit pe baza unui pachet de mediu ROS (*Robotic Operating System*).

Hierarchical Deep Q-Network (H-DQN), o soluție bazată pe învățarea prin întărire profundă ierarhică (*hierarchical deep reinforcement learning*), este utilizată într-un context SMDP (*Semi-Markov Decision Process*) (Qin și alții 2022, 1-15). Această tehnică poate echilibra calitatea serviciilor (*Quality of Services – QoS*) și securitatea energetică. În plus, se adaptează bine la condițiile schimbătoare, folosind o varietate de senzori și cerințe. Conceptul este aplicabil UAS-IoT cu surse de energie minime, operațiunilor autonome cu drone în zone cu infrastructură limitată și monitorizării mediului.

Un algoritm pentru navigația UAV și pentru evitarea obstacolelor în scenarii de inundații este prezentat într-o altă lucrare care se concentrează pe învățarea prin întărire profundă (*Deep Reinforcement Learning – DRL*) și pe aplicarea acesteia la UAV-uri ([Garg și Jha 2024](#), 1-12). Acest algoritm permite controlul autonom al mai multor UAV-uri în vederea colectării de date despre obstacole și determinării rutelor sigure pentru vehiculele de evacuare pe apă.

În lucrarea *”Neural network model for autonomous navigation of a water drone”* este prezentat un model de rețea neuronală pentru navigarea autonomă a unei drone acvatice într-un mediu fluvial simulat ([Chekmezov și Molchanov 2024](#), 4-16). RL este folosit pentru îmbunătățirea evitării obstacolelor și adaptării la curenții de apă, garantând o navigație eficientă, în condiții dinamice. Mergând mai departe către tema simulării UAV, apar studii care se concentrează pe simularea software-în-bucă (*Software-in-the-Loop Simulation*) pentru testarea algoritmilor de viziune pe un UAV cu patru rotoare (*quad-rotor*), utilizând Gazebo pentru simulare și PX4 pentru controlul zborului ([Nguyen și Nguyen 2019](#), 429-432; [Nguyen, Nguyen și Ha 2019](#), 615–627). Aceste aspecte pot fi utilizate și pentru simulările ulterioare din acest articol.

Securitatea UAV-urilor este un alt factor important care nu trebuie neglijat. O altă lucrare implementează un model ML de clasificare în trei clase pe un UAV, folosind un procesor Raspberry Pi pentru a clasifica atacurile de tip GPS spoofing în timp real, utilizând caracteristici specifice GPS pentru detectare și clasificare eficientă în aplicațiile dependente de locație ([Nayfeh și alții 2023](#), 289-292). Folosind un extractor de caracteristici CNN și clasificatori ML, într-un studiu se prezintă un sistem cu cost redus, bazat pe Raspberry Pi 4, care utilizează ML pentru detectarea și clasificarea UAS-urilor (*Unmanned Aerial Systems*), obținând o acuratețe de 100% în detectarea pe două clase și 90,9% în clasificarea tipului de UAS ([Swinney și Woods 2022](#), 14). În plus, lucrarea *”Autonomous Control with Vision and Deep Learning: A Raspberry Pi Edge Computing Platform for Obstacle Detection in SUAV Path”* arată că această funcționalitate poate fi folosită pentru detectarea obstacolelor la drone de mici dimensiuni (*Small Unmanned Aerial Vehicles – SUAVs*), echipate cu Raspberry Pi ([Ullah și alții 2024](#), 1-9). Această configurație sporește siguranța navigației prin evitarea obstacolelor în timp real, în medii complexe. În materie de securitate, în vederea unei contracarări active, se pot utiliza sistemele antidronă C-UAS, care reprezintă o cerință de bază pentru ca forțele terestre să poată să opereze pe câmpul de luptă modern ([Watling și Bronk 2024](#)).

Pentru a rezuma acest subcapitol, cu accent pe eficiența energetică, pe adaptare în timp real și securitate, literatura de specialitate analizată manifestă un interes puternic în privința aplicării învățării automate – în special rețele neuronale profunde, învățarea prin întărire și învățarea prin imitație – pentru îmbunătățirea autonomiei, navigației, evitării obstacolelor, colectării datelor și comunicațiilor UAV-urilor în medii acvatice sau ostile, dificile și dinamice. De asemenea, o problemă majoră identificată este necesitatea acordării unei atenții deosebite credibilității și fiabilității ML în operațiunile și aplicațiile UAV ([Kurunathan și alții 2024](#), 1-28).

2. Metodologia

2.1. Cadrul

Studiul se bazează pe cercetarea conceptului pe care se sprijină implementarea inteligenței artificiale în dispozitive tip quadcopter, care vor putea răspunde cerințelor utilizatorului, în diferite medii amfibii și în diverse scopuri. Pentru a înțelege conceptul din spatele îmbunătățirii controlului UAS, obiectivul inițial a fost de a găsi răspunsuri la câteva întrebări:

- Ce trebuie să conțină sistemul dronei pentru a putea realiza învățarea automată?
- Ce tip de învățare automată poate fi folosit?
- Ce parametri trebuie luați în considerare atunci când este utilizată în medii ostile?
- Ce aplicații pot fi folosite ulterior pentru a simula aceste cadre de rețea?
- Cum pot fi integrați algoritmi de învățare automată pentru a permite UAV-urilor să se adapteze în timp real la condiții incerte din mediile fluviale, în situații militare?

Lucrarea de cercetare are un caracter calitativ prin faptul că, pe baza analizei literaturii de specialitate și a sintezelor realizate, se caută noi răspunsuri la întrebările de cercetare, formulate anterior, obiectivul cercetării fiind generarea de noi cunoștințe teoretice și stabilirea unui cadru conceptual pentru implementarea inteligenței artificiale în sistemele aeriene fără pilot.

Metoda de culegere a datelor a reprezentat-o analiza documentară, prin colectarea datelor și extragerea informațiilor esențiale din diferite surse, pentru a vedea tendințele și direcțiile de cercetare ale diverșilor autori, în domeniu. Ca metodă de analiză calitativă, a fost folosită analiza tematică.

Această abordare a fost aleasă pentru a evidenția informații de interes privind subiectul ales, precum și pentru a stabili baza cercetărilor viitoare, care ar include simulări și metode practice, folosind dispozitive reale. Contribuția duce la sistematizarea aspectelor legate de controlul UAV-urilor, ceea ce face posibilă simularea mai facilă a UAS-urilor în mediul virtual, respectând parametrii critici. După simularea acestora în spațiul virtual, se poate trece la programarea practică a unui dispozitiv real, prin „injectarea” inteligenței artificiale pentru a reduce diferența dintre cerințele utilizatorului și senzorii inteligenței ai dispozitivului.

Limitele studiului includ lipsa echipamentelor fizice pentru simulare și testare directă, ceea ce duce la absența experimentelor practice, necesare validării rezultatelor într-un mediu virtual și, apoi, real.

2.2. Baza conceptuală

Analizând lucrările de specialitate, se poate observa că acestea converg către principii comune și aprobă necesitatea îmbunătățirii unor elemente ale UAS-urilor, însă de prea puține ori, se discută despre un cadru conceptual singular, care să unifice toate aceste elemente ale UAS-urilor, astfel încât să se obțină o soluție viabilă

și eficientă în aria sistemelor de drone aeriene. Un asemenea cadru poate fi folosit din sistemul ROS, care este construit pentru a oferi o abordare modulară pentru aplicații robotice. Dezvoltarea individuală a blocurilor funcționale poate fi foarte utilă, în special atunci când se proiectează aplicații de complexitate ridicată. Această abordare permite o dezvoltare simplă, deoarece fiecare bloc are o sarcină extrem de specifică ([Antonopoulos și alții 2022](#), 5).

Astfel, având în vedere modelul modular al ROS și observațiile unor specialiști, legate de unele module care ar trebui dezvoltate, precum motorul de inferență ML ([Foehn și alții 2022](#), 2), modulul de monitorizare a bateriei ([Barrientos și alții 2011](#), 13) și de supraveghere ([Queralta și alții 2020](#), 11), pentru a permite operarea inteligentă și autonomă a UAV-urilor în medii acvatice, se propune o arhitectură modulară care să susțină coordonarea multiagent, luarea deciziilor în timp real și autonomia bazată pe ML. O arhitectură modulară similară a fost dezvoltată, însă pentru operațiuni de căutare și salvare (Search and Rescue – SAR) ([Queralta și alții 2020](#), 1-2). Contribuția prezentei lucrări se axează pe această abordare validată, însă adaptată la provocările mediilor acvatice, riverane, punându-se accent pe modulul de decizie bazat pe ML.

Arhitectura include componente atât la bordul UAV-ului, cât și la nivel de margine (*edge-level*), combinând fuziunea senzorilor (*sensor fusion*), inferența ML, logica de control și comunicarea interagent, în care datele colectate de senzori sunt procesate local (la bord), iar deciziile privind zborul, aterizarea sau predarea misiunii (*handover*) sunt luate autonom, cu sprijinul unui modul ML. Această abordare modulară UAV – navă a fost aleasă, deoarece permite integrarea funcțiilor critice, precum cele ale senzorilor, controlului, energiei, comunicațiilor și ML într-un cadru scalabil și robust, capabil să răspundă specificațiilor mediilor fluviale. De asemenea, se justifică prin literatura de specialitate recentă, care arată că modularitatea și procesarea distribuită sporesc autonomia și reziliența UAS-urilor în coordonarea multiagent ([Antonopoulos și alții 2022](#); [Foehn și alții 2022](#); [Jung și alții 2024](#)).

În cadrul acestei arhitecturi, vor exista două subsisteme: UAV-ul și nava fluvială centrală. Cele două subsisteme sunt interconectate printr-o legătură de comunicații (C2) și alcătuiesc, de fapt, sistemul general de drone aeriene fără pilot (UAS). Fiecare subsistem este caracterizat prin mai multe module specifice (Figura 2), după cum urmează:

Modulul de senzori (GPS, IMU – *Inertial Measurement Unit*, barometru, camere de bord) asigură localizarea și percepția mediului înconjurător, fiind fundamentul proceselor de fuziune a senzorilor ([Du și alții 2020](#)). Datele colectate sunt apoi procesate de către un modul de inferență ML, care evaluează stările operaționale (de exemplu: proximitatea față de navă, nivelul bateriei, siguranța aterizării etc.). Rolul acestui modul este prezentat în lucrarea lui P. Foehn, care demonstrează că rularea pe modele ML direct pe UAV are implicații rapide la nivel de reacție în medii dinamice ([Foehn și alții 2022](#)).

Pentru ca deciziile la nivel de algoritm să fie transpuse în mișcări precise, arhitectura trebuie să includă un modul de control al zborului. Acesta face legătura dintre

algoritmii ML sau RL și sistemul de pilot automat, folosind ROS 2 sau PX4 (Nguyen și Nguyen 2019), astfel traducând comportamentele inteligente în comenzi executabile. Monitorizarea autonomiei este asigurată de un modul de baterie, componentă necesară pentru managementul energiei și pentru luarea deciziilor critice, element esențial în structura unui UAS inteligent. De asemenea, realizarea schimbului de date cu alte UAV-uri și cu nava centrală, în concordanță cu conceptele de coordonare interagent, prezentate de J.P. Queralta ar fi efectuată cu ajutorul unui modul de comunicații, închizându-se arhitectura la nivel de UAV (Queralta 2020).

În ceea ce privește vasul/nava centrală, aceasta reprezintă, practic, o stație de control, iar subsistemul cuprinde un modul de supraveghere UAV, responsabil de monitorizarea dronelor active și de declanșarea procedurilor de handover, lansând un nou UAV atunci când unul revine pentru încărcare sau când se defectează, astfel asigurându-se continuitatea misiunii. Această funcționalitate este similară strategiilor de coordonare la nivel de roi de drone, cercetate de W. Jung (Jung și alții 2024, 7).

Diferența dintre cele două subsisteme este că, în timp ce platforma UAV are modul de ML pentru a lua decizii foarte rapide, legate de menținerea poziției, evitarea coliziunilor, ajustarea altitudinii etc. la nivel individual, nava centrală are o perspectivă asupra întregului roi de drone avut la dispoziție, având detaliile critice ale fiecărei platforme UAV și putând iniția acțiuni multiagent. Această navă centrală reprezintă și platforma de aterizare pentru subsistemele UAV.




Figura 2 Componentele arhitecturii UAS

Fluxul operațional, pe baza diagramei de mai sus, presupune ca UAV-ul să monitorizeze continuu poziția, altitudinea și nivelul bateriei, în timp ce modulul ML Inference determină dacă UAV-ul se află într-o stare operațională sigură. Dacă este detectată o stare critică, drona efectuează o aterizare autonomă pe nava fluvială, în timp ce modulul de supraveghere al navei declanșează lansarea unui UAV de rezervă pentru a continua misiunea. Această arhitectură poate fi implementată în ROS 2 cu PX4 (MathWorks, fără an) și simulată în Gazebo, utilizând date reale privind dinamica fluvială și aeriană.

Tabelul următor reprezintă un design RL simplificat, axat pe recompense (Guo și alții 2023; Kong și alții 2023; Tovarnov și Bykov 2022), pentru a înțelege mai bine

controlul UAV, bazat pe învățare prin întărire, cu menținerea perimetrului într-un mediu fluvial (Tabelul nr. 1).

TABEL NR. 1

Design RL simplificat pentru controlul UAV

Starea (S)	Acțiunea (A)	Recompensa (R)
Cât timp distanța < 10 m față de navă & bateria > 30%	Menținerea poziției	+5
Distanța între 10m și 15m	Ajustarea poziției	+1
Distanța > 15m	Revenirea către navă	0
Bateria < 20%	Aterizarea pe platforma navei	+5 / -5
Coliziune	Oricare sau N/A	-10

Această abordare introduce autonomie, care se adaptează la schimbările de mediu în timp real (Tabelul nr. 2), inclusiv la dinamica curenților fluviali și la coridoare înguste, fără a fi nevoie de praguri fixe, bazate pe reguli.

TABEL NR. 2

Design RL simplificat, bazat pe schimbări de mediu

Starea (S)	Acțiunea (A)	Recompensa (R)
Viteza vântului < 5m/s	Menținerea normală a zborului	+3
Viteza vântului între 5m/s și 10 m/s	Ajustarea direcției/forței	+1 / -1
Viteza vântului > 10m/s	Inițierea aterizării de urgență	+ 5 / - 5
Vizibilitatea < 100m	Reducerea vitezei, activarea senzorilor suplimentari	+3
Temperatura între -10°C și 40°C	Ajustarea modului de economisire a baterie/aterizarea	-3
Umiditatea > 90%	Activarea modului de protecție a senzorilor	+1 / -3

3. Rezultatele cercetării

3.1. Analiza cadrului teoretic și conceptual

Analizând literatura de specialitate, precum și cadrul propus anterior, se găsesc următoarele răspunsuri la întrebările de cercetare, formulate în Secțiunea 2:

În primul rând, pentru a permite integrarea învățării automate, o dronă trebuie să prezinte o arhitectură similară cu cea descrisă, care combină elemente atât hardware, cât și software. Componentele/modulele au fost descrise în capitolul anterior. În ceea ce privește tipul de ML care poate fi folosit, ținând cont de natura mediului acvatic, caracterizat prin variabilitate și incertitudine, cel mai potrivit tip de învățare automată este cel prin întărire – RL. Acesta permite UAS-urilor să învețe prin interacțiune cu mediul, adaptându-se la situații noi și optimizând deciziile pe baza punctelor de recompensă sau de penalizare, scopul fiind de a maximiza punctajul obținut. În aplicații mai complexe, pot fi folosite și variante mai complexe de ML, precum Deep Q-Network sau învățarea hibridă.

Pentru a răspunde la a treia întrebare de cercetare, parametrii care trebuie luați în calcul în mediile acvatice ostile includ condițiile atmosferice (viteza și direcția

vântului, presiunea atmosferică), condițiile hidrologice (curenții de apă, nivelul apei, turbulențele generate de obstacole), precum și obstacolele statice și dinamice (poduri, vegetație de mal, alte ambarcațiuni). Parametrii tehnici interni, precum nivelul bateriei, stabilitatea semnalului de comunicație și precizia poziționării GPS, sunt, de asemenea, determinanți pentru succesul misiunii. Integrarea acestor date prin fuziune de senzori și utilizarea lor în algoritmi ML permit UAS-urilor să ia decizii robuste și să reducă vulnerabilitatea la condiții ostile.

Sistemele de drone aeriene în mediile fluviale pot fi validate și testate în cadrul unor aplicații, precum ROS 2, integrat cu PX4, care permite dezvoltarea modulară a componentelor UAV. Gazebo, de asemenea, poate fi folosit pentru simulări, în care factorii de mediu pot fi modificați astfel încât să fie redată obstacolele și condițiile atmosferice nefavorabile specifice mediului fluvial. Aceste tipuri de aplicații duc la creșterea realismului și valorii practice a cercetărilor care prevăd sisteme de drone, în general.

Nu în ultimul rând, pentru a integra algoritmi de ML în această tehnologie a dronelor, este nevoie de implementarea inteligenței artificiale la nivel de dispozitiv UAV, prin arhitectura prezentată, dar și la nivelul întregului sistem, incluzând stația sau centrul de control. UAV-ul, printr-un model ușor de ML, devine capabil de microdecizii, care trebuie luate într-un timp foarte scurt, pe când sistemul, prin stația de control și prin centrul de colectare a datelor, trebuie să fie capabil de perspectiva macrodecizională, având situația de ansamblu a tuturor dronelor din teren simultan, precum și a imaginii operaționale comune (Common Operational Picture – COP), mereu actualizată (Figura 3). O utilizare combinată a tuturor platformelor fără pilot ar conduce la un sistem multidomeniu eficient operațional care oferă o imagine operațională comună mai completă, datorită prezenței în cele trei medii – terestru, aerian și maritim. Fiecare platformă are ariile ei care pot fi dezvoltate, multe aspecte fiind comune, după cum se poate observa în compendiul realizat în cadrul UNIDIR (Grand-Clément 2023, 12-16).



Figura 3 Imaginea operațională comună (COP) cu ajutorul sistemelor de drone aeriene
(Sursă: <https://www.magaero.com/wp-content/uploads/2023/02/KINETIC-STRIKE-TRAINING-PROGRAM-KSTP-Image-1643901249160-RT.jpg>)

Mediile acvatice și cursurile de apă (fluvii, râuri, canale, estuare) prezintă o serie de particularități în ceea ce privește influența lor asupra platformelor aeriene fără pilot. Acestea se deosebesc prin spații înguste, condiții dinamice variabile și distanța mică până la mal. Curenții de apă, prin viteza și direcția lor, au impact asupra navelor care sunt platforme de aterizare pentru drone, acest lucru solicitând UAV-ul să-și calculeze poziția și traiectoria permanent. Apropierea de mal presupune, practic, posibila apropiere de obstacole sau de obiecte care pot reprezenta obstacole, fie că este vorba despre infrastructură creată de om sau vegetații specifice locului. De asemenea, infrastructura poate reprezenta și o sursă de interferență electromagnetică, care să perturbe calitatea comunicațiilor dintre platforma UAV și stația de control.

Prin integrarea ML și a inteligenței artificiale, în general, sistemele de drone pot învăța să reacționeze optim la curenți, pe baza scenariilor, simulate anterior și memorate în unitatea lor. De asemenea, pe baza AI-ului pot lua decizii în timp real, detectând și evitând obstacolele autonom, fără intervenția utilizatorului uman. Se asigură, astfel, o reziliență atât pentru domeniul civil, cât și pentru cel militar, prin anticiparea riscurilor și reducerea timpilor de reacție la nivelul întregului sistem de drone, care poate include un număr mărit de astfel de platforme aeriene mobile.

3.2. Rezultate privind controlul autonom al UAV în mediul fluvial pe baza recompensei

O distanță de până la 10 metri față de navă este considerată sigură, atâta timp cât bateria este peste 30%. Aceasta fiind varianta pe care UAV-ul trebuie să învețe să o respecte, va fi punctată cel mai mult, iar drona va trebui să își mențină poziția. Dacă distanța crește, prin modulul de control al zborului (flight control module), drona va trebui să își ajusteze poziția și va primi doar un punct. Dacă distanța depășește valoarea maximă de 15 metri, atunci se află în afara perimetrului aerian stabilit pentru navă. În acest caz, UAV-ul trebuie să revină în zona desemnată.

Dacă bateria scade sub 20%, ceea ce reprezintă un nivel critic, deoarece autonomia bateriei dronelor nu este mare, UAV-ul trebuie să aterizeze pe platforma navei, simultan cu al doilea UAV, aflat în așteptare, care trebuie, acum, să se activeze și să zboare, înlocuind drona cu bateria descărcată. Dacă prima dronă aterizează cu succes, va primi +5 puncte. Dacă nu reușește să aterizeze corect sau în timp util, primește un scor de -5. În cele din urmă, în cazul unei coliziuni între drone sau cu mediul, se aplică o penalizare de -10 puncte.

Întregul concept învață automat sistemele tehnologice, prin învățare prin întărire, să se comporte conform scorului maxim, modelându-l pe baza caracteristicilor stabilite de mintea umană. Cu toate acestea, condițiile atmosferice nu pot fi ignorate în acest sens. Fiecare UAV are senzori specifici pentru măsurarea parametrilor de mediu (de exemplu, un anemometru pentru viteza vântului, senzori barometrice pentru presiunea atmosferică, GPS pentru localizare în timp real și LiDAR pentru detectarea obstacolelor). Datele sunt utilizate în algoritmi ML pentru a adapta zborul, în funcție de condițiile reale, deoarece acestea afectează atât modelul dinamic al UAV-ului, cât și deciziile autonome (de exemplu, aterizarea atunci când vântul

este prea puternic). Procesul de învățare poate beneficia și de scenarii simulate de defectare, în care UAV-urile se abat de la comportamentul optim. Penalizarea acestor scenarii ajută agentul să învețe mai rapid strategii de rezervă robuste. Deși simularea s-a bazat pe o fizică idealizată, viitoarele lucrări ar trebui să includă validarea cu date reale de telemetrie din zborurile UAV în medii acvatice, pentru a asigura fidelitatea comportamentului învățat.

Este important ca atât factorii de mediu externi (de exemplu, curenții de aer, vegetația etc.), cât și condițiile interne ale sistemelor UAV (nivelul bateriei, stabilitatea legăturilor de comunicații etc.) să fie într-un cadru unificat de evaluare a riscurilor, așa după cum se arată într-un articol de cercetare în domeniul siguranței și securității (Terje 2007, 745–754). Modelul dronelor bazat pe învățare automată nu ar trebui să se axeze doar pe optimizarea navigației, ci și pe evaluarea continuă a riscurilor și vulnerabilităților specifice mediului în care operează, astfel încât să fie rezistente, sigure și precise.

Din perspectivă operațională, arhitectura propusă și folosirea învățării prin întărire contribuie direct la procesul militar de luare a deciziei (MDMP – The Military Decision-Making Process), fiind ușor de urmărit în cele redate mai jos (Tabelul nr. 3). Astfel, se observă faptul că UAS-urile pot funcționa pe principiul MDMP sau pot fi utilizate în procesul de luare a deciziei de către personalul militar.

TABEL NR. 3

Corelația dintre procesul militar de luare a deciziei și arhitectura modulară UAV

Nr. crt.	Etapa	Corelația
1	Primirea misiunii (Receipt of Mission)	UAV-urile pot fi integrate rapid într-o misiune specifică, înțelegând și adaptându-se cerințelor primite de la eșalonul superior, inclusiv la constrângeri de timp, spațiu și resurse.
2	Analiza misiunii (Mission Analysis)	Senzorii integrați și modulele ML furnizează date esențiale despre mediu (curenți de apă, obstacole naturale, condiții meteorologice), facilitând identificarea sarcinilor critice și anticiparea riscurilor în spațiul de operare. Esențial pentru compartimentul S2, când UAS furnizează informații.
3	Elaborarea cursurilor de acțiune (Course of Action – COA Development)	Prin utilizarea RL și a algoritmilor de predicție, UAV-urile pot genera mai multe variante de acțiune (drumul cel mai scurt sau personalizat, menținerea perimetrului, aterizarea pe navă, handover între drone), care pot fi adaptate în timp real. De asemenea, cursurile de acțiune, stabilite de către eșalon, pot fi implementate direct în UAS-uri.
4	Analiza cursurilor de acțiune (COA Analysis)	Simulările bazate pe ML permit testarea și evaluarea fiecărui curs de acțiune în condiții fluviale complexe, identificând punctele forte, vulnerabilitățile și potențialele riscuri, înainte de implementare.
5	Compararea cursurilor de acțiune (COA Comparison)	Datele rezultate din evaluările anterioare pot fi comparate între ele, în cadrul mai multor cursuri de acțiune, oferind comandantului o imagine obiectivă asupra soluției optime. Dacă această etapă este integrată în subsistemul UAV, atunci aceasta va fi capabilă să aleagă cea mai bună variantă posibilă.
6	Aprobarea cursului de acțiune (COA Approval)	Prin UAS-uri, se pot transmite date sintetizate și recomandări, facilitând procesul de selecție a cursului de acțiune cel mai viabil către comandant.
7	Elaborarea și transmiterea ordinelor (Orders Production)	Integrarea UAV-urilor într-o rețea coordonată și robustă permite transpunerea deciziei aprobate într-un plan operațional executabil, unde fiecare dronă primește roluri clare, sincronizate cu misiunea generală.

3.3. Viitoare direcții

Având datele referitoare la aspectele care trebuie luate în considerare în ceea ce privește controlul unei drone prin ML, autorul poate trece la pasul următor, care presupune implementarea hardware a unei drone fizice, capabile de ML. Un astfel de dispozitiv UAV este construit modular, pornind de la un cadru fizic, precum cele din figurile de mai jos (Figura 3 și Figura 4), pe care este montat hardware electronic standardizat.



Figura 3 F450 Quadrotor Drone
(Sursă: <https://www.jsumo.com/f450-droneunassembled-4337-15-K.jpg>)



Figura 4 QAV250 Quadrotor Drone
(sursă: https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcQ5J_RzkS0IFLSAmAWAFVvRQ1P5YIDShJKriQ&s)

Acest sistem este controlat de un controler de zbor cu sursă deschisă (*open-source flight controller*), cum ar fi Pixhawk, care rulează firmware, precum PX4 sau ArduPilot, unele dintre cele mai avansate și populare sisteme software pentru drone autonome. Acest controler de zbor utilizează informații din depozitul PX4 pentru a îmbunătăți siguranța misiunilor UAV și eficiența operațională a ArduPilot (Tovarnov și Bykov 2022). Platforma poate fi construită manual, cu componente disponibile și separat. După asamblarea pieselor, conectarea motoarelor, electronicelor și senzorilor și după montarea acestora pe platformă, aceasta poate fi configurată la nivel software cu aplicații precum QGroundControl (QGC). Acest dispozitiv este capabil să execute comenzi multiple și variate: zbor autonom, menținerea perimetrului, detectarea evenimentelor, reacții imediate și automate, aterizare automată, predare (*handover*) între drone etc. În plus, acest tip de UAV este potrivit pentru simulări virtuale, folosind aplicații precum Gazebo și AirSim, unde pot fi utilizați parametrii de mediu. Fiind open-source, înseamnă că sistemul are control complet asupra firmware-ului de comunicație, având compatibilitate cu calculatoare single-board (*Single-Board Computers – SBC*), cum ar fi Raspberry Pi sau Jetson. Prezintă un avantaj considerabil în ceea ce privește costul redus și accesibilitatea, precum și popularitatea.

Implementând inteligența artificială pe bază de învățare automată și configurând aspectele prezentate anterior, s-ar putea face ca dronele să devină mult mai eficiente și utilizabile în agricultură, optimizând timpul activităților în agricultura de precizie (Petre și alții 2022, 105). În ceea ce privește dezavantajele, probabil cel mai mare dezavantaj este autonomia redusă a bateriei și protecția fizică, dar care poate fi îmbunătățită prin utilizarea unor protecții suplimentare pentru carcasa platformei. Din cauza limitărilor tehnologice ale bateriilor, dronele nu pot avea o sarcină utilă suplimentară sau crescută, deoarece acest lucru îi perturbă precizia (Boșcoianu și alții 2024, 12).

De asemenea, tot limitările bateriilor sunt cauza problemei majore în rândul dronelor, indiferent de domeniul în care acționează, fiind unul dintre punctele slabe ale acestor tehnologii, aflate încă la începutul dezvoltării lor (Iagăru și alții 2023, 296).

Viitoare lucrări vor implica utilizarea unor drone fizice reale, cu cost redus, capabile de ML, și analiza comportamentului acestora, fiind supuse la experimente în medii amfibii și programate, conform cerințelor prezentate în această lucrare.

Concluzii

Integrarea tehnicilor de învățare automată în controlul UAS-urilor prezintă oportunități promițătoare pentru îmbunătățirea operațiunilor autonome în medii acvatice complexe, cum ar fi râurile și pâraiele. Aceste medii ridică provocări unice, inclusiv curenți de apă, condiții meteorologice variabile și constrângeri spațiale, cauzate de vegetație și infrastructură.

În cadrul arhitecturii modulare, se poate integra la nivelul modulelor de AI atât procesul militar de luare a deciziilor, cât și posibilitatea învățării automate pe bază de recompense și penalizări. Prin acest control al UAS pe bază de ML, se ajunge la o coordonare interagent între UAV-uri, caracterizată de transmiterea datelor atât către platforma centrală (nava), cât și către un centru de colectare a datelor din teren, astfel fiind posibilă crearea și consolidarea imaginii operaționale comune în timp real și într-un mod continuu, actualizat, pe baza procedurii de handover între drone. Acest proces sprijină succesul operațiilor de ISR (Intelligence, Surveillance, Reconnaissance), căutare-salvare și sprijin militar. De asemenea, prin aceste mecanisme de handover și prin monitorizarea bateriei, se poate asigura managementul energetic al UAS-urilor, devenind posibilă prelungirea duratei operaționale, fără intervenție umană directă, reducând costurile logistice și riscurile pentru personalul militar implicat în acțiuni.

Strategiile de control bazate pe ML permit UAV-urilor să se adapteze la astfel de incertitudini în timp real, prin învățarea unor comportamente de zbor robuste, navigare coordonată multiagent și luarea deciziilor, în funcție de context (context-aware decision-making). Perspectivile cheie includ dezvoltarea de algoritmi adaptivi pentru menținerea formației și a poziției, în raport cu platformele în mișcare, aterizarea autonomă fiabilă pe nave, în condiții de apă fluctuante și protocoale de handover fără întreruperi, pentru a extinde durata misiunii. În plus, integrarea senzorilor de mediu în timp real în modelele ML le îmbunătățește reziliența în fața perturbărilor atmosferice și a variabilității hidrologice.

Întrebările de cercetare au primit răspuns complet prin definirea arhitecturii UAS și selectarea tipurilor adecvate de ML. Au fost identificați parametrii specifici mediului fluvial ostil, prezentate în cadrul tabelului. Au fost menționate unele aplicații specifice simulărilor virtuale care pot fi folosite pentru validarea perspectivei de integrare a UAS-urilor cu ML și a utilizării acestora în condiții nefavorabile, pe baza factorilor de mediu care pot fi modificați ușor în cadrul acestor simulări. Dar, pentru a putea integra UAS-urile cu ML, este nevoie, separat, de un modul de AI la nivelul

UAV-ului propriu-zis, cât și la nivelul sistemului, mai precis la nivelul stației de control și al centrului de colectare a datelor, astfel încât perspectiva pe care o oferă sistemul să fie una întreagă, de ansamblu. Cu toate acestea, întrebările de cercetare sunt limitate la un nivel mai mult teoretic, din cauza lipsei de echipamente și a simulării propriu-zise a cadrului arhitectural modular prezentat.

Viitoarele cercetări ar trebui să se concentreze pe perfecționarea mediilor de simulare care modelează cu acuratețe dinamica acvatică, combinată cu comportamentul UAV-urilor, extinderea seturilor de date pentru antrenarea controlerelor ML în scenarii diverse și validarea abordărilor prin implementări în condiții reale.

Prin valorificarea potențialului ML, sistemele aeriene fără pilot pot atinge un nivel mai ridicat de autonomie, siguranță și eficiență, deschizând noi aplicații în monitorizarea mediului, căutare și salvare și inspecția infrastructurii acvatice în diverse domenii, inclusiv în cel militar. Cu toate acestea, pentru a-l utiliza în domeniul militar, ar trebui dezvoltată o perspectivă suplimentară de cercetare privind elaborarea unor protocoale standardizate care să asigure o comunicare fiabilă și cu latență redusă între UAV-uri și platformele fluviale, permițând comportamente coordonate și integrarea sistemelor provenite de la furnizori diferiți la nivel internațional.

Referințe

- Antonopoulos, Antonis, Michail G. Lagoudakis și Panagiotis Partsinevelos.** 2022. "A ROS Multi-Tier UAV Localization Module Based on GNSS, Inertial and Visual-Depth Data." *Drones* 6(6): 135. <https://doi.org/10.3390/drones6060135>.
- Barrientos, A., J. Colorado, J. del Cerro, A. Martínez, C. Rossi și D. Sanz.** 2011. "Aerial remote sensing in agriculture: A practical approach to monitoring energy and mission performance." *Sensors* 18(8): 2559. <https://doi.org/10.1002/rob.20403>.
- Boșcoianu, Mircea, Sebastian Pop, Pompilica Iagăru, Lucian-Ionel Cioca, Romulus Iagăru și Ioana Mădălina Petre.** 2024. "An Innovative Management Framework for Smart Horticulture – The Integration of Hype Cycle Paradigm" *Drones* 8, no. 7: 291. <https://doi.org/10.3390/drones8070291>.
- Chellapandi, V. P., Liang Yuan, Stanisław H. Żak și Zhaojian Wang.** 2023. "A Survey of Federated Learning for Connected and Automated Vehicles." În *2023 IEEE 26th International Conference on Intelligent Transportation Systems (ITSC)*, 2485–92. Bilbao, Spain. <https://doi.org/10.1109/ITSC57777.2023.10421974>.
- Chekmezov, H. și O. Molchanov.** 2024. "Neural Network Model for Autonomous Navigation of a Water Drone." *Information, Computing and Intelligent Systems Journal*, no. 5: 4–16. <https://doi.org/10.20535/2786-8729.5.2024.315700>.
- Du, H., W.Wang, C. Xu, R. Xiao și C. Sun.** 2020. "Real-Time Onboard 3D State Estimation of an Unmanned Aerial Vehicle in Multi-Environments Using Multi-Sensor Data Fusion." *Sensors* 20: 919. <https://doi.org/10.3390/s20030919>.
- Foehn, P., E. Kaufmann, M. Gehrig, R. Ranftl, A. Dosovitskiy, V. Koltun și D. Scaramuzza.** 2022. "Agile autonomous drone flight using end-to-end deep reinforcement learning." *Science Robotics* 7(66). <https://www.science.org/doi/10.1126/scirobotics.abl6259>.

- Garg, Armaan și Shashi Jha.** 2024. „Multi-UAV Assisted Flood Navigation of Waterborne Vehicles Using Deep Reinforcement Learning.” *Journal of Computing and Information Science in Engineering* 24: 1–12. <https://doi.org/10.1115/1.4066025>.
- Grand-Clément, Sarah.** 2023. „Uncrewed Aerial, Ground, and Maritime Systems: A Compendium.” <https://doi.org/10.37559/CAAP/23/ERC/05>.
- Guo, Y., N. Zhang, H. Jiang, J. Li și Q.-Y. Fan.** 2023. ”Layered Reinforcement Learning Design for Safe Flight Control of UAV in Urban Environments.” 673–78. <https://doi.org/10.1109/csis-iac60628.2023.10363849>.
- Haris, Malik și Jin Hou.** 2020. ”Obstacle Detection and Safely Navigate the Autonomous Vehicle from Unexpected Obstacles on the Driving Lane.” *Sensors* 20(17): 4719. <https://doi.org/10.3390/s20174719>.
- Hassanalain, Mostafa și Abdeslam Abdelkefi.** 2017. „Classifications, Applications, and Design Challenges of Drones: A Review.” *Progress in Aerospace Sciences* 91: 99–131. <https://doi.org/10.1016/j.paerosci.2017.04.003>.
- Iagăru P., M. Boșcoianu, I.L. Cioca, I.M. Petre, S. Pop, F.A. Sârbu și R. Iagăru.** 2023. ”Critical Analysis of Mini Unmanned Aerial Vehicles (UAV) Development Capabilities and Perspectives of Effective Integration in Horticultural Agroecosystems in Romania”. Scientific Papers. Series “Management, Economic Engineering in Agriculture and Rural Development”, Vol. 23 Issue 1, 293-302. ISSN 2284-7995. https://managementjournal.usamv.ro/pdf/vol.23_1/Art33.pdf.
- Jung, Wooyong, Changmin Park, Seunghyeon Lee și Hwangnam Kim.** 2024. ”Enhancing UAV Swarm Tactics with Edge AI: Adaptive Decision Making in Changing Environments.” *Drones* 8(10): 582. <https://doi.org/10.3390/drones8100582>.
- Khan, A., J.R. Campos, N. Ivaki și H. Madeira.** 2023. ”A Machine Learning Driven Fault Tolerance Mechanism for UAVs’ Flight Controller.” 217–27. <https://doi.org/10.1109/prdc59308.2023.00034>.
- Kong, S., M. Li, Y. Zhou și Z. Wang.** 2023. ”Effective Control of Unmanned Aerial Vehicles Based on Reward Shaping.” 135–39. <https://doi.org/10.1109/rcae59706.2023.10398796>.
- Kurunathan, H., H. Huang, K. Li, W. Ni și E. Hossain.** 2024. ”Machine Learning-Aided Operations and Communications of Unmanned Aerial Vehicles: A Contemporary Survey.” <https://doi.org/10.1109/comst.2023.3312221>.
- Maharjan, Narayan, Hiroaki Miyazaki, Bikash M. Pati, Matthew N. Dailey, Sudeep Shrestha și Takayuki Nakamura.** 2022. ”Detection of River Plastic Using UAV Sensor Data and Deep Learning.” *Remote Sensing* 14(13): 3049. <https://doi.org/10.3390/rs14133049>.
- MathWorks, fără an.** ”Control a Simulated UAV Using ROS 2 and PX4 Bridge.” Accesat 20 iulie 2025. <https://www.mathworks.com/help/ros/ug/control-a-simulated-uav-using-ros2-and-px4-bridge.html>.
- Nayfeh, M., J. Price, M. A. Alkhatib, K. Al Shamaileh, N. Kaabouch și V. K. Devabhakuni.** 2023. ”A Real-Time Machine Learning-Based GPS Spoofing Solution for Location-Dependent UAV Applications.” 289–93. <https://doi.org/10.1109/eit57321.2023.10187344>.
- Negru, Sorin A., Patrick Geragersian, Ivan Petrunin și Weisi Guo.** 2024. ”Resilient Multi-Sensor UAV Navigation with a Hybrid Federated Fusion Architecture.” *Sensors* 24(3): 981. <https://doi.org/10.3390/s24030981>.

- Nguyen, Kim D. și Toan-Tuan Nguyen.** 2019. "Vision-Based Software-in-the-Loop-Simulation for Unmanned Aerial Vehicles Using Gazebo and PX4 Open Source." În *International Conference on System Science and Engineering*, 429–32. <https://doi.org/10.1109/ICSSE.2019.8823322>.
- Nguyen, Kim D., Toan-Tuan Nguyen și Chien Ha.** 2019. "Graph-SLAM Based Hardware-in-the-Loop-Simulation for Unmanned Aerial Vehicles Using Gazebo and PX4 Open Source." În *Lecture Notes in Computer Science*, 615–27. Cham: Springer. https://doi.org/10.1007/978-3-030-26969-2_58.
- Nomikos, Nikolaos, Panagiotis K. Gkonis, Panayiotis S. Bithas și Panagiotis Trakadas.** 2023. "A Survey on UAV-Aided Maritime Communications: Deployment Considerations, Applications, and Future Challenges." *IEEE Open Journal of the Communications Society* 4: 56–78. <https://doi.org/10.1109/OJCOMS.2022.3225590>.
- Petre, Ioana, Mircea Boșcoianu, Sebastian Pop, Pompilica Iagăru, Flavius Aurelian Sârbu și Romulus Iagăru.** 2022. "An Analysis of the Possibilities to Develop and Implement a Modular and Scalable System Based on Mini-Aerial Robots for Precision Agriculture." *RECENT – REzultatele CErcetărilor Noastre Tehnice*. 23. 100-106. <https://doi.org/10.31926/RECENT.2022.68.100>.
- Qin, Zhen, Xiaojie Zhang, Xinyu Zhang, Bin Lu, Zhiqiang Liu și Lihua Guo.** 2022. "The UAV Trajectory Optimization for Data Collection from Time-Constrained IoT Devices: A Hierarchical Deep Q-Network Approach." *Applied Sciences* 12(5): 2546. <https://doi.org/10.3390/app12052546>.
- Queraltà, J.P., J. Taipalmaa, B.C. Pullinen, V.K. Sarker, T.N. Gia, H. Tenhunen și T. Westerlund.** 2020. "Collaborative Multi-Robot Search and Rescue: Planning, Coordination, Perception, and Active Vision." în *IEEE Access*, vol. 8, pp. 191617-191643. <https://doi.org/10.1109/ACCESS.2020.3030190>.
- Samus, Mykhailo.** 2024. "Lessons Learned from the War in Ukraine: The Impact of Drones." <https://newstrategycenter.ro/wp-content/uploads/2024/02/Lessons-Learned-from-the-War-in-Ukraine.-The-impact-of-Drones-2.pdf>.
- Sarkar, Nurul I. și Sonia Gul.** 2023. "Artificial Intelligence-Based Autonomous UAV Networks: A Survey." *Drones* 7 (5): 322. <https://doi.org/10.3390/drones7050322>.
- Song, G.G.** 2022. "A Deep Reinforcement Learning Strategy for UAV Autonomous Landing on a Platform." *2022 International Conference on Robotics and Smart System (ICRSS)*, 104–9. <https://doi.org/10.1109/ICRSS57469.2022.00031>.
- Swinney, C.J. și J.C. Woods.** 2022. "Low-Cost Raspberry-Pi-Based UAS Detection and Classification System Using Machine Learning." *Aerospace* 9(12): 738. <https://doi.org/10.3390/aerospace9120738>.
- Terje A.** 2007. "A unified framework for risk and vulnerability analysis covering both safety and security". *Reliability Engineering & System Safety* 92(6): 745-754. <https://doi.org/10.1016/j.res.2006.03.008>.
- Tovarnov, M.S. și N.V. Bykov.** 2022. "Reinforcement Learning Reward Function in Unmanned Aerial Vehicle Control Tasks." *Journal of Physics: Conference Series* 2308(1): 012004. <https://doi.org/10.1088/1742-6596/2308/1/012004>.
- Ullah, F., M. Hayajneh, N. AbuAli, H. Asad, F. S. Malik și B. F. Mon.** 2024. "Autonomous Control with Vision and Deep Learning: A Raspberry Pi Edge Computing Platform for Obstacle Detection in SUAV Path." 1–9. <https://doi.org/10.1109/commnet63022.2024.10793296>.

- Wang, Zhaojian, Jianwen Li și Nina Mahmoudian.** 2024. "Synergistic Reinforcement and Imitation Learning for Vision-Driven Autonomous Flight of UAV Along River." *2024 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 9976–82. Abu Dhabi, United Arab Emirates. <https://doi.org/10.1109/IROS58592.2024.10801487>.
- Watling, J. și J. Bronk.** 2024. "Protecting Land Forces from Uncrewed Aerial Systems (UAS)". <https://static.rusi.org/protecting-the-force-from-uncrewed-uas.pdf>.
- Wu, Lin, Chao Wang, Pengfei Zhang și Chao Wei.** 2022. "Deep Reinforcement Learning with Corrective Feedback for Autonomous UAV Landing on a Mobile Platform." *Drones* 6 (9): 238. <https://doi.org/10.3390/drones6090238>.
- Zhao, Chenjie, Ryan Wen Liu, Jingxiang Qu și Ruobin Gao.** 2024. "Deep Learning-Based Object Detection in Maritime Unmanned Aerial Vehicle Imagery: Review and Experimental Comparisons." *Engineering Applications of Artificial Intelligence* 128: 107513. <https://doi.org/10.1016/j.engappai.2023.107513>.