

DOI: <https://doi.org/10.36719/2789-6919/57/231-236>

İsmayıl Vəliyev
Azərbaycan Dövlət İqtisad Universiteti
magistrant
<https://orcid.org/0009-0007-4376-9804>
vliyevismayil70@gmail.com

Dronlarda real vaxt rejimində qərarvermə üçün maşın öyrənmə yanaşmaları

Xülasə

Müasir aviasiya sistemlərinin inkişafı ilə birlikdə pilotsuz uçuş aparatları (dronlar) həm hərbi, həm də mülki sahələrdə geniş tətbiq tapmışdır. Real vaxt rejimində qərarvermə dronların effektivliyini birbaşa müəyyənləşdirən ən kritik texniki tələblərdən biridir. Ənənəvi əmr-idarəetmə sistemləri mürəkkəb və dinamik mühitlərdə kifayət qədər çevik reaksiya verə bilmir. Bu məqalədə dronlarda real vaxt rejimində qərarvermə üçün maşın öyrənmə metodlarının tətbiqi kompleks şəkildə araşdırılmışdır. Tədqiqat çərçivəsində mövcud dərin öyrənmə, gücləndirici öyrənmə və hibrid yanaşmalar təhlil edilmiş, onların üstünlükləri, məhdudiyyətləri və praktiki tətbiq imkanları müəyyən olunmuşdur. Xüsusilə hesablama resurslarının məhdudluğu, gecikmə tələbləri və mühitin qeyri-müəyyənliyi kimi amillər real vaxt sistemlərinin əsas meyarları kimi qiymətləndirilmişdir.

Açar sözlər: *dron, pilotsuz uçuş aparatı, maşın öyrənmə, dərin öyrənmə, gücləndirici öyrənmə, real vaxt qərarvermə, avtonom sistemlər, neyron şəbəkəsi*

Ismayil Valiyev
Azerbaijan State University of Economics
Master's student
<https://orcid.org/0009-0007-4376-9804>
vliyevismayil70@gmail.com

Machine Learning Approaches for Real-Time Decision Making in Drones

Abstract

With the rapid advancement of modern aviation systems, unmanned aerial vehicles (drones) have found widespread application in both military and civilian domains. Real-time decision making is one of the most critical technical requirements directly determining drone effectiveness. Traditional command-and-control systems lack sufficient agility to respond in complex and dynamic environments. This paper comprehensively examines the application of machine learning methods for real-time decision making in drones. Within the research framework, existing deep learning, reinforcement learning, and hybrid approaches are analyzed, along with their advantages, limitations, and practical implementation prospects. Computational resource constraints, latency requirements, and environmental uncertainty are identified as key criteria for real-time systems. The paper proposes an adaptive decision index model to evaluate and select the most appropriate machine learning approach based on the operational context.

Keywords: *drone, unmanned aerial vehicle, machine learning, deep learning, reinforcement learning, real-time decision making, autonomous systems, neural network*

Giriş

Pilotsuz uçuş aparatlarının (PUA) müasir texnologiyalarla inteqrasiyası son onillikdə dramatik sürətlə inkişaf etmişdir. Əvvəlcə yalnız hərbi kəşfiyyat məqsədi ilə istifadə olunan dronlar bu gün yangın söndürmə, kənd təsərrüfatı, infrastrukturun monitorinqi, çatdırılma xidmətləri və axtarış-xilasətmə əməliyyatlarında geniş tətbiq sahəsi tapır. Bu genişlənmə ilə birlikdə dronlara olan tələblər də əhəmiyyətli dərəcədə artmışdır, xüsusilə mürəkkəb, dəyişkən və qeyri-müəyyən şəraitdə müstəqil qərarvermə bacarığı ön plana keçmişdir.

Real vaxt qərarvermə problemi dronlar üçün fundamental texniki çətinliklərdən birini təmsil edir. Ənənəvi deterministik alqoritmlər əvvəlcədən proqramlaşdırılmış qaydalar çərçivəsində fəaliyyət göstərir və dinamik mühitin tələblərinə uyğunlaşma qabiliyyəti məhduddur. Maşın öyrənmə metodları isə bu problemi fərqli rəqəsdən həll edir: verilənlərdən öyrənmə, nümunə tanıma və adaptiv davranış formalaşdırma vasitəsilə dron sistemləri bilinməyən situasiyalarda da səmərəli qərarlar qəbul edə bilir (Goodfellow və b., 2016; Sutton və Barto, 2018; Shah və b., 2018).

Bu məqalənin aktuallığı bir neçə amillə müəyyən edilir. Birincisi, dron texnologiyalarının sürətli inkişafı istifadə ssenarilərini genişləndirir və daha çətin qərarvermə tələblərini doğurur. İkincisi, maşın öyrənmə metodologiyalarının inkişafı xüsusilə dərin öyrənmə və gücləndirici öyrənmə bu sahədə yeni imkanlar açmışdır. Üçüncüsü, real vaxt tələblərinin yerinə yetirilməsi hesablama resursları baxımından ciddi məhdudiyyətlər yaradır ki, bu da metodların seçilməsini mürəkkəbləşdirir. Tədqiqatın məqsədi mövcud maşın öyrənmə yanaşmalarını sistemli şəkildə təhlil etmək, onların dronlarda real vaxt tətbiqinə uyğunluğunu qiymətləndirmək və praktiki tövsiyələr işləyib hazırlamaqdır.

Tədqiqat

Dron sistemlərinin real vaxt qərarvermə tələbləri. Dronlarda real vaxt qərarvermə sistemi bir sıra əsas funksional tələbləri eyni zamanda icra etməlidir. Bu tələblər arasında ən əhəmiyyətli gecikmə (latency) məsələsidir: qərarvermə dövrü sensordan verilənlər alınması, işlənməsi, qərar qəbul edilməsi və icra əmrinin verilməsi mərhələlərini əhatə edir. Əksər tətbiqlər üçün bu dövrün 100 millisaniyədən az olması tələb olunur, xüsusən maneədən qaçma kimi kritik tapşırıqlarda bu dəyər 10-50 millisaniyə həddindədir.

Dronların işlədildiyi mühitlər, adətən, yüksək qeyri-müəyyənlik ilə xarakterizə olunur: hava şəraitinin dəyişkənliyi, digər obyektlərlə qarşılaşma ehtimalı, GPS signalının zəifliyi və vizual mühitin mürəkkəbliyi sistemin etibarlılığına ciddi tələblər qoyur. Bundan əlavə, dronlar enerji resursları baxımından məhdud cihazlardır; güclü hesablama prosessorları enerji istehlakını artıraraq uçuş müddətini azaldır. Bu ziddiyyətin həlli maşın öyrənmə modelinin seçilməsində əsas meyar rolunu oynayır.

Real vaxt qərarvermə üçün maşın öyrənmə metodları. Dronlarda real vaxt qərarvermə üçün istifadə olunan maşın öyrənmə metodları bir neçə əsas kateqoriyaya bölünür. Hər bir yanaşmanın özünəməxsus üstünlükləri, məhdudiyyətləri və uyğun tətbiq sahələri mövcuddur.

Dərin öyrənmə (Deep Learning, DL) yanaşmaları arasında konvolusiya neyron şəbəkələri (CNN) vizual məlumatların emalında əldə etdiyi yüksək nəticələr sayəsində dron sistemlərində geniş tətbiq olunur. CNN arxitekturaları kamera görüntülərindən maneələrin aşkarlanması, obyektlərin tanınması və yer səthinin xəritələnməsi kimi tapşırıqları yüksək dəqiqliklə yerinə yetirə bilir. Lakin standart CNN modelləri böyük hesablama resursları tələb edir ki, bu da real vaxt rejimində tətbiqi çətinləşdirir (LeCun və b., 2015; Mnih və b., 2015; Schmidhuber, 2015). Bu məhdudiyyəti aradan qaldırmaq məqsədilə MobileNet, SqueezeNet və EfficientNet kimi optimallaşdırılmış yüngül arxitekturalar hazırlanmışdır.

Rekurrent neyron şəbəkələri (RNN) və onun inkişaf etmiş forması olan LSTM (Long Short-Term Memory) ardıcıl verilənlərin emalında geniş tətbiq olunur və xüsusilə uçuş trayektoriyasının proqnozlaşdırılması, sensor ardıcılıqlarının təhlili və zaman sıralarının öyrənilməsi kimi sahələrdə yüksək effektivlik nümayiş etdirir. Bu yanaşmalar dronun davranış tarixçəsini nəzərə alaraq gələcək qərarların daha dəqiq şəkildə formalaşdırılmasına şərait yaradır.

Gücləndirici öyrənmə (Reinforcement Learning, RL) dronların ətraf mühitlə qarşılıqlı təsir əsasında öyrənməsinə şərait yaradan bir yanaşmadır. Bu çərçivədə dron agent kimi fəaliyyət göstərir, mühit daxilində müxtəlif hərəkətlər icra edir və həmin hərəkətlərə uyğun olaraq mükafat və ya cəza signalları ilə geri bildirim alır. Müasir RL metodları olan Derin Q-şəbəkəsi (DQN), Proximal Policy Optimization (PPO) və Soft Actor-Critic (SAC) alqoritmləri mürəkkəb uçuş davranışlarının idarə olunması, çox-agentli sistemlərdə koordinasiya və uzunmüddətli qərarvermə problemlərinin həllində yüksək effektivlik göstərir.

Hibrid yanaşmalar isə yuxarıda qeyd olunan metodların üstünlüklərini birləşdirərək onların mövcud məhdudiyyətlərini azaldır. Məsələn, CNN və RL birlikdə tətbiq edildikdə, CNN vizual mühitdən alınan məlumatların emalını həyata keçirir, RL isə həmin emal olunmuş məlumatlar əsasında idarəetmə qərarlarını formalaşdırır. Bu cür integrasiya həm qavrama dəqiqliyini, həm də qərarvermə prosesinin adaptivliyini artırır.

Cədvəl 1.

Maşın öyrənmə metodlarının müqayisəli qiymətləndirilməsi

Metod	Dəqiqlik	Hesablama Yüku	Real Vaxt Uyğunluğu	Əsas Tətbiq
CNN (yüngülləşdirilmiş)	Yüksək	Orta	Yüksək	Vizual tanıma
LSTM/RNN	Orta-Yüksək	Orta	Orta	Traektoriya proqnozu
DQN (RL)	Yüksək	Yüksək	Orta	Maneədən qaçma
PPO (RL)	Yüksək	Orta	Yüksək	Uçuş idarəetməsi
CNN+RL Hibrid	Çox Yüksək	Yüksək	Orta	Mürəkkəb ssenarilər

Müasir texnologiyalar və dron qərarvermə sistemlərinə təsiri. Kənar hesablama (Edge Computing) texnologiyalarının inkişafı dronlarda real vaxt rejimində maşın öyrənmə tətbiqlərinin praktiki icrasına mühüm təsir göstərmişdir. NVIDIA Jetson, Google Coral və Intel Neural Compute Stick kimi kənar hesablama qurğuları neyron şəbəkə modellərinin birbaşa dronun bort avadanlığı üzərində işlədilməsinə imkan yaradır. Bu yanaşma bulud serverlərindən asılılığı azaldır, gecikməni minimuma endirir və şəbəkə bağlantısı olmadan da sistemin fəaliyyətini təmin edir.

Model sıxışdırması (Model Compression) üsulları böyük ölçülü neyron şəbəkə modellərinin resurs məhdudiyyətləri olan cihazlarda icrasını təmin etmək baxımından mühüm rol oynayır. Budama (Pruning), kvantlaşdırma (Quantization) və bilik distilasiyası (Knowledge Distillation) kimi texnikalar modelin ölçüsünü əhəmiyyətli dərəcədə, hətta 90%-ə qədər azaltmağa imkan verir, eyni zamanda onun dəqiqliyini böyük ölçüdə qoruyur. Məsələn, float32 formatında olan tam dəqiqlikli modelin int8 formatına kvantlaşdırılması yaddaş sərfiyyatını və hesablama vaxtını xeyli dərəcədə azaldır.

Çox-agent sistemləri (Multi-Agent Systems) bir neçə dronun koordinasiyalı şəkildə birgə tapşırıqları icra etdiyi hallarda maşın öyrənmə yanaşmalarının tətbiqini daha da mürəkkəbləşdirir. Birgə gücləndirici öyrənmə (Cooperative Reinforcement Learning) metodları dronlar arasında qarşılıqlı əlaqənin qurulmasına, məlumatların paylaşılmasına və kollektiv qərarvermə mexanizmlərinin formalaşmasına şərait yaradır. Bu cür yanaşma axtarış-xilasətmə əməliyyatları, ərazilərin monitorinqi və böyük həcmli çatdırılma sistemlərində effektivliyin artırılmasına mühüm töhfə verir.

Simulyasiya mühitlərinin rolu da xüsusi əhəmiyyət kəsb edir. AirSim, Gazebo və OpenAI Gym əsasında hazırlanmış dron simulyatorları maşın öyrənmə modellərinin böyük həcmdə məlumat

üzərində öyrədilməsinə, müxtəlif əməliyyat ssenarilərinin test edilməsinə və real mühitdə tətbiqdən əvvəl sistemlərin yoxlanılmasına imkan verir. Bununla belə, simulyasiya mühitindən real dünyaya keçid zamanı ortaya çıxan “Sim-to-Real gap” problemi hələ də aktual tədqiqat istiqaməti olaraq qalmaqdadır.

Real vaxt qərarvermə sistemlərinin tətbiqindəki əsas çətinliklər. Dronlarda real vaxt rejimində maşın öyrənmə sistemlərinin tətbiqi zamanı bir sıra fundamental texniki çətinliklər ortaya çıxır. İlk növbədə, verilənlərin etibarlılığı problemi diqqət cəkkir: sensor xətalrı, uçuş zamanı yaranan vibrasiyalar və işıqlandırma şəraitindəki dəyişikliklər giriş məlumatlarının keyfiyyətini azaldır və nəticə etibarilə maşın öyrənmə modellərinin çıxışına mənfi təsir göstərir (Han və b., 2016; Zhu və Allibert, 2023). Robust (dayanıqlı) model arxitekturalarının hazırlanması bu problemi qismən azaltsa da, onu tam şəkildə aradan qaldırmaq hələ də mümkün olmamışdır.

İkinci mühüm məsələ paylanmış (dağıdılmış) və mərkəzləşdirilmiş öyrənmə yanaşmaları arasında optimal balansın təmin olunmasıdır. Dronun bortunda yerləşən prosessor vasitəsilə yerində öyrənmə həyata keçirilərsə, bu, sistemin çevikliyini və operativliyini artırır, lakin eyni zamanda hesablama yükünün artmasına səbəb olur (Shi və b., 2016). Digər tərəfdən, öyrənmə prosesinin yerüstü serverlərdə aparılması və yalnız hazır modelin drona integrasiya edilməsi resurs sərfiyyatını azaltsa da, real mühitdə adaptivlik səviyyəsini məhdudlaşdırır.

Üçüncü əsas məsələ etibarlılıq (reliability) və xəta davamlılığı tələblərinin yüksək səviyyədə təmin olunması ilə bağlıdır. Maşın öyrənmə modellərinin qeyri-deterministik təbiəti onların təhlükəsizlik baxımından kritik sistemlərdə sertifikatlaşdırılmasını mürəkkəbləşdirir (Seshia və b., 2018; Juliani və b., 2020; Müller və b., 2018). Bu kontekstdə formal doğrulama üsullarının maşın öyrənmə sistemlərinə integrasiyası hazırda fəal şəkildə araşdırılan tədqiqat istiqamətlərindən biri hesab olunur.

Dördüncü mühüm problem sahələrarası keçid (domain transfer) məsələsi ilə bağlıdır: müəyyən bir mühitdə öyrədilmiş model fərqli əməliyyat şəraitində eyni performans səviyyəsini qoruyub saxlaya bilmir. Transfer öyrənmə (Transfer Learning) yanaşmaları bu problemin həllinə qismən töhfə versə də, dron sistemlərinin müxtəlif və dinamik mühitlərdə sabit fəaliyyətini tam şəkildə təmin etmək hələ də mümkün olmamışdır.

Adaptiv Qərarvermə İndeksinin formalaşdırılması. Bu tədqiqat çərçivəsində dron sistemlərinin real vaxt qərarvermə vəzifəsi üçün ən uyğun maşın öyrənmə yanaşmasının seçilməsinə yardımçı olan rəsmiləşdirilmiş model təklif olunur (Koch və b., 2019; Li və b., 2021). Adaptiv Qərarvermə İndeksi (AQİ) anlayışına əsaslanan bu mexanizm dörd əsas əməliyyat parametrini nəzərə alır.

Cədvəl 2.

Adaptiv Qərarvermə İndeksinin parametrləri

Parametr	Simvol	Aralıq	Şərh
Mühit mürəkkəbliyi	E	1-5	Uçuş şəraitinin qeyri-müəyyənlik dərəcəsi
Hesablama resursu	C	1-5	Bortdakı prosessor gücünün mövcudluğu
Gecikmə tələbi	L	1-5	Tətbiqin tələb etdiyi cavab vaxtı sıxlığı
Öyrənmə yetkinliyi	M	1-5	Mövcud model optimallaşdırma səviyyəsi

Adaptiv Qərarvermə İndeksi (AQİ) aşağıdakı kimi hesablanır:

$$AQİ = (E \times L) / (C + M)$$

E yüksəkdirsə → adaptiv hibrid yanaşma tələb olunur;

L yüksəkdirsə → yüngülləşdirilmiş, sürətli modellərə üstünlük verilməlidir;

C və M zəifdirsə → mərhələli tətbiq və model sıxışdırması vacibdir.

Bu indeksə əsasən:

$AQİ > 2$ olduqda → Hibrid DL+RL yanaşması (mərhələli nəzarətlərlə) tövsiyə edilir;

$1 \leq AQİ \leq 2$ olduqda → Yüngülləşdirilmiş DL (MobileNet, EfficientNet-Lite) tövsiyə edilir;

$AQİ < 1$ olduqda → Klassik deterministik alqoritmlər və ya əvvəlcədən öyrədilmiş statik modellər tövsiyə edilir.

Nəticə

Aparılan tədqiqat göstərir ki, dronlarda real vaxt qərarvermə üçün vahid, universal maşın öyrənmə yanaşması mövcud deyil; metodun seçimi tətbiq kontekstindən, əməliyyat mühitindən, mövcud hesablama resurslarından və gecikmə tələblərindən birbaşa asılıdır. Dərin öyrənmə metodları vizual məlumatların emalında yüksək dəqiqliyi ilə seçilsə də, onların yüksək hesablama tələbləri real vaxt tətbiqlərini məhdudlaşdırır. Gücləndirici öyrənmə isə mürəkkəb və dinamik mühitlərdə adaptiv davranışın formalaşdırılmasında yüksək potensial nümayiş etdirir, lakin öyrənmə prosesinin uzunluğu və etibarlılıq məsələləri hələ də həllini tapmamış problemlər kimi qalır.

Tədqiqatın nəticələrinə əsasən, dronlarda real vaxt qərarvermə sistemlərinin effektivliyi bir sıra əsas prinsiplərə söykənməlidir: mövcud resurslara uyğun model seçimi, kənar hesablama texnologiyalarının tətbiqi, model sıxışdırılması üsullarından istifadə və simulyasiya mühitlərinin sistemli şəkildə inteqrasiyası. Bununla yanaşı, hüquqi çərçivənin, xüsusilə aviasiya sahəsində sertifikatlaşdırma tələblərinin, maşın öyrənmə texnologiyalarının inkişafını nəzərə alacaq formada təkmilləşdirilməsi vacib istiqamətlərdən biri kimi müəyyən edilir.

Təklif edilən Adaptiv Qərarvermə İndeksi (AQİ) modeli praktiki tətbiq mühitində uyğun metodun seçilməsi üçün sadə, lakin əsaslandırılmış yanaşma təqdim edir. Bu model mühitin mürəkkəbliyi səviyyəsini, hesablama imkanlarını, gecikmə tələblərini və modelin yetkinlik dərəcəsini kompleks şəkildə qiymətləndirməyə imkan verir. Gələcək tədqiqat istiqamətləri kimi çox-agentli dron sistemlərində koordinasiyanın təkmilləşdirilməsi, Sim-to-Real keçid probleminin aradan qaldırılması, formal doğrulama metodlarının inkişaf etdirilməsi və kənar hesablama platformalarının optimallaşdırılması xüsusi əhəmiyyət kəsb edir.

Ədəbiyyat

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
2. Han, S., Mao, H., & Dally, W. J. (2016). *Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding*. ICLR.
3. Juliani, A., Berges, V. P., Teng, E., et al. (2020). *Unity: A general platform for intelligent agents*. arXiv:1809.02627.
4. Koch, W., Mancuso, R., West, R., & Bestavros, A. (2019). Reinforcement learning for UAV attitude control. *ACM Transactions on Cyber-Physical Systems*, 3(2), 22.
5. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
6. Li, J., Deng, X., & Li, Z. (2021). Deep reinforcement learning for autonomous UAV navigation in dynamic environments. *IEEE Transactions on Vehicular Technology*, 70(4), 3818–3829.
7. Mnih, V., Kavukcuoglu, K., Silver, D., et al. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529–533.
8. Müller, M., Dosovitskiy, A., Ghanem, B., & Koltun, V. (2018). *Driving policy transfer via modularity and abstraction*. In *Conference on Robot Learning*. PMLR.
9. Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117.

10. Seshia, S.A., Sadigh, D., & Sastry, S.S. (2018). *Formal specification for deep neural networks*. In ATVA 2018, LNCS 11138.
11. Shah, S., Dey, D., Lovett, C., & Kapoor, A. (2018). *AirSim: High-fidelity visual and physical simulation for autonomous vehicles*. In *Field and Service Robotics*. Springer.
12. Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637–646.
13. Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction*. MIT Press.
14. Zhu, H., & Allibert, G. (2023). Real-Time Decision Making for Autonomous Drones Using Lightweight Neural Architectures. *Journal of Field Robotics*, 40(3), 511–527.

Received: 07.01.2026

Approved: 14.04.2026