

Sistem Pemantauan Kebakaran Berbasis Drone: Deteksi Asap Real-Time, Navigasi Cerdas Berbasis Deep Reinforcement Learning, dan Estimasi Luas Area Terdampak

Drone-Based Fire Monitoring System: Real-Time Smoke Detection, Deep Reinforcement Learning-Based Intelligent Navigation, and Fire Impact Area Estimation

Adi Sucipto¹, Rifqi Aji Widarso², Tamara Maharani³, Dhodit Rengga Tisna⁴

^{1,2} Jurusan Teknologi Informasi, Politeknik Negeri Jember

^{3,4} Jurusan Teknologi Multimedia, Akademi Komunitas Negeri Pacitan, Pacitan, Indonesia

Email : rifqiaji_w@polije.ac.id

ABSTRACT

Forest and land fires require monitoring systems that can detect early smoke, guide safe drone navigation, and estimate affected areas rapidly. This study develops an unmanned aerial vehicle(UAV)based fire monitoring system that combines a modified YOLOv8 smoke detector, Deep Reinforcement Learning navigation using Proximal Policy Optimization, and DeepLabV3+ semantic segmentation for burned-area estimation. The detector is improved using SPPF+, CBAM attention, WIoU loss, and TensorRT INT8 optimization for edge deployment. Formal ablation experiments using a 23 factorial design confirm synergistic effects among the three components. On FLAME2 and D-Fire benchmarks, YOLOv8-Smoke outperforms the strongest baseline by 2.3 and 1.5 mAP@0.5 points, respectively. Statistical significance tests (Welch's t-test, $p < 0.01$) confirm that improvements over all baselines are significant. Sensitivity analysis of the smoke threshold τ_c and reward component ablation are reported. Failure cases under extreme smoke density are visualized and discussed. The navigation module learns adaptive maneuvers from simulated and field fire scenarios, while geospatial calibration converts segmented pixels into hectares. Evaluations on simulated fires, controlled burn trials, and real fire cases show that the detector achieves 91.7% mAP@0.5 with 34 ms latency, the Proximal Policy Optimization (PPO) navigation reaches 97.1% avoidance success, and the area estimation obtains 88.3% average accuracy against Sentinel-2 reference data. These results indicate that the integrated framework is suitable for real-time wildfire monitoring and can complement conventional satellite-based observation.

Keywords : area estimation, deep reinforcement learning, drone, smoke detection, wildfire monitoring.

ABSTRAK

Kebakaran hutan dan lahan membutuhkan sistem pemantauan yang mampu mendeteksi asap lebih awal, membantu navigasi drone secara aman, dan memperkirakan luas area terdampak secara cepat. Penelitian ini mengembangkan sistem pemantauan kebakaran berbasis *unmanned aerial vehicle* (UAV) yang menggabungkan deteksi asap YOLOv8 termodifikasi, navigasi Deep Reinforcement Learning menggunakan Proximal Policy Optimization, serta segmentasi semantik DeepLabV3+ untuk estimasi area terbakar. Eksperimen ablasi faktorial 23 mengonfirmasi efek sinergis antar komponen. Pada FLAME2 dan D-Fire, YOLOv8-Smoke melampaui baseline terkuat sebesar 2,3 dan 1,5 poin mAP@0,5. Uji signifikansi statistik (Welch's t-test, $p < 0,01$) mengonfirmasi perbedaan bermakna terhadap semua baseline. Analisis sensitivitas τ_c dan ablasi reward dilaporkan. Failure cases pada kondisi ekstrem divisualisasikan. Model deteksi diperkuat dengan SPPF+, attention CBAM, WIoU loss, dan optimasi TensorRT INT8 agar sesuai untuk perangkat edge. Modul navigasi mempelajari manuver adaptif dari skenario simulasi dan pengujian lapangan, sedangkan kalibrasi geospasial mengubah hasil segmentasi piksel menjadi luas hektar. Pengujian pada kebakaran simulasi, controlled burn, dan kasus kebakaran nyata menunjukkan bahwa model deteksi mencapai mAP@0,5 sebesar 91,7% dengan latensi 34 ms, navigasi *Proximal Policy Optimization* (PPO) mencapai keberhasilan penghindaran 97,1%, dan estimasi luas area memperoleh akurasi rata-rata 88,3% terhadap data referensi Sentinel-2. Hasil ini menunjukkan bahwa kerangka terintegrasi layak digunakan untuk pemantauan kebakaran real-time dan dapat melengkapi observasi berbasis satelit.

Kata kunci: deep reinforcement learning, deteksi asap, drone, estimasi area, monitoring kebakaran.

A. PENDAHULUAN

Kebakaran hutan dan lahan merupakan bencana yang berdampak langsung pada lingkungan, kesehatan, transportasi, dan kegiatan ekonomi masyarakat[1]. Pada wilayah yang memiliki lahan gambut, api dapat menyebar melalui permukaan maupun lapisan bawah tanah sehingga proses deteksi dan pemadaman menjadi lebih kompleks. Oleh sebab itu, informasi awal mengenai lokasi asap, arah penyebaran, dan luas area terdampak diperlukan dalam waktu yang sangat cepat.

Teknologi drone atau *Unmanned Aircraft System (UAV)* menawarkan alternatif yang lebih fleksibel karena dapat terbang rendah, mengambil citra beresolusi tinggi, dan menjangkau area yang sulit diakses kendaraan darat[2]. Meskipun *Unmanned Aircraft System (UAV)* menjanjikan, operasi pada lingkungan kebakaran memiliki risiko yang tidak dapat diabaikan. Asap pekat dapat mengganggu kualitas citra, mempersulit estimasi jarak, dan menurunkan kemampuan operator dalam menentukan lintasan aman[3]. Kondisi tersebut menyebabkan rute statis menjadi kurang sesuai, sehingga diperlukan sistem navigasi yang mampu beradaptasi terhadap perubahan lingkungan secara real-time[2][4].

Penelitian ini mengusulkan sistem pemantauan kebakaran berbasis drone yang mengintegrasikan tiga modul utama. Modul pertama adalah deteksi asap real-time menggunakan YOLOv8-Smoke yang ditingkatkan dengan SPPF+, CBAM, dan WIoU[5][6]. Modul kedua adalah navigasi cerdas berbasis Deep Reinforcement Learning dengan algoritma *Proximal Policy Optimization (PPO)* untuk menghindari zona asap berbahaya. Modul ketiga adalah estimasi luas area terdampak berbasis segmentasi semantik DeepLabV3+ dan kalibrasi geospasial. Integrasi ini dirancang agar sistem tidak hanya mendeteksi kebakaran, tetapi juga mendukung keselamatan penerbangan dan pengambilan keputusan lapangan.

Untuk mendukung reproduksibilitas, naskah ini dilengkapi paket supplementary yang memuat konfigurasi *Proximal Policy Optimization (PPO)*, koefisien reward, parameter domain randomization, aturan action safety shield, dan protokol anotasi segmentasi. Karena repositori khusus penelitian belum dipublikasikan, implementasi terbuka pada

https://github.com/leeshun/forest_fire_detection_system digunakan hanya sebagai rujukan teknis untuk arsitektur pemantauan kebakaran berbasis *Unmanned Aircraft System (UAV)*, bukan sebagai repositori resmi kode penelitian ini. Dataset benchmark tersedia pada <https://github.com/gaiasolutionsondemand/DFireDataset> dan https://github.com/xiwenci/Flame_2_dataset. Rujukan implementasi navigasi dan segmentasi tersedia pada https://github.com/heleidsn/UAV_Navigation_DRL_AirSim dan <https://github.com/maidacundo/real-time-fire-segmentation-deep-learning>.

B. LANDASAN TEORI

A. Pemantauan Kebakaran Berbasis UAV

Unmanned Aircraft System (UAV) banyak digunakan untuk pemantauan bencana karena dapat membawa kamera RGB, termal, dan multispektral pada area yang sulit dijangkau[5][6]. Drone rotary-wing cocok untuk inspeksi titik tertentu karena dapat melakukan hovering, sedangkan drone fixed-wing lebih unggul untuk pemetaan area luas. Pada pemantauan kebakaran, citra dari *(UAV)* memberikan resolusi spasial tinggi sehingga operator dapat mengamati pola asap dan batas area terdampak dengan lebih detail[2].

Kelebihan utama *Unmanned Aircraft System (UAV)* terletak pada fleksibilitas pengambilan data[4]. Namun, pemanfaatan *Unmanned Aircraft System (UAV)* tetap memerlukan sistem komputasi yang ringan dan cepat agar proses deteksi, peringatan, serta pengiriman informasi ke Ground Control Station tidak terlambat.

B. Deteksi Asap Menggunakan Deep Learning

Asap kebakaran memiliki karakteristik visual yang sulit dipisahkan dari awan, kabut, atau debu. Bentuknya amorf, batasnya tidak tegas, dan warnanya berubah bergantung pada material yang terbakar[7]. Metode berbasis threshold warna atau tekstur sering gagal pada kondisi pencahayaan ekstrem[4]. Oleh sebab itu, pendekatan deep learning lebih sesuai karena mampu mempelajari fitur spasial yang kompleks dari data citra.

Sebelum era deep learning, deteksi asap kebakaran dari citra UAV umumnya menggunakan metode berbasis aturan (color thresholding), fitur handcrafted (Histogram of Oriented Gradients, LBP), dan clas-sifier konvensional (SVM, Random Forest)[8]. Pendekatan tersebut mengalami degradasi signifikan pada kondisi pencahayaan berubah, asap tipis berlatar awan, dan sudut pandang rendah. Perbandingan eksplisit terhadap metode non-deep learning disertakan pada Tabel 6 untuk menunjukkan nilai tambah arsitektur yang diusulkan.

FLAME2[9] merupakan dataset kebakaran hutan publik yang dikumpulkan melalui penerbangan UAV di wilayah hutan Arizona, Amerika Serikat. Dataset ini memuat 2.942 citra RGB beresolusi tinggi dengan anotasi bounding box untuk objek api dan asap. Sementara itu, D-Fire[10] terdiri atas 21.527 citra beranotasi api dan asap yang berasal dari berbagai perangkat, termasuk kamera UAV, CCTV, dan smartphone. Variasi sumber akuisisi tersebut menghasilkan kondisi visual yang lebih beragam. Kedua dataset dipilih sebagai benchmark karena telah digunakan dalam penelitian sejenis, sehingga kinerja model yang diusulkan dapat dibandingkan secara langsung pada data pengujian yang terukur.

C. Navigasi Unmanned Aircraft System (UAV) Berbasis Deep Reinforcement Learning

Deep Reinforcement Learning memodelkan agen yang belajar melalui interaksi dengan lingkungan. Agen menerima state, memilih aksi, lalu memperoleh reward sebagai umpan balik. Pada navigasi *Unmanned Aircraft System* UAV, pendekatan ini bermanfaat karena agen dapat belajar menghindari bahaya dinamis tanpa harus mendefinisikan semua aturan lintasan secara eksplisit[6]. *Proximal Policy Optimization* (PPO) digunakan karena mekanisme clipped surrogate membantu menjaga pembaruan kebijakan tetap stabil pada ruang aksi kontinu.

D. Segmentasi dan Estimasi Area

Estimasi area kebakaran membutuhkan segmentasi piksel untuk membedakan area terbakar, asap, vegetasi, dan latar belakang. DeepLabV3+ sesuai untuk tugas ini karena mampu menangkap konteks multi-skala. Setelah


piksel terdampak teridentifikasi, luas nyata dihitung dengan ground sampling distance berdasarkan tinggi terbang, ukuran piksel sensor, dan panjang fokus kamera[11].

C. METODE PENELITIAN

A. Pemantauan Kebakaran Berbasis Unmanned Aircraft System UAV

Sistem menggunakan pendekatan edge-cloud hybrid. Deteksi asap dan navigasi dijalankan pada perangkat onboard agar keputusan manuver tidak bergantung sepenuhnya pada jaringan[12]. Estimasi area dan penyimpanan historis dapat dibantu oleh server Ground Control Station. Alur kerja sistem dimulai dari akuisisi citra RGB/IR, deteksi asap, pembentukan state navigasi, inferensi kebijakan PPO, segmentasi area, dan penyajian hasil pada antarmuka operator.


Dalam rancangan ini, YOLOv8-smoke memberikan confidence asap yang menjadi masukan penting bagi agen navigasi[11][13]. Agen *Proximal Policy Optimization* (PPO) kemudian menghasilkan perubahan kecepatan dan arah yaw untuk menjaga drone tetap berada pada rute aman. Di sisi lain, hasil segmentasi DeepLabV3+ digunakan untuk memperkirakan luas area terdampak dan memperbarui peta bahaya yang terlihat pada GCS.



Gambar 1 Arsitektur sistem pemantauan kebakaran berbasis drone

Platform yang digunakan adalah quadrotor DJI Neo yang dimodifikasi (Gambar 2), dengan unit komputasi NVIDIA Jetson Orin NX (16 GB LPDDR5, GPU Ampere 1024-core + 32 DLA) untuk

inferensi deep learning onboard. Sistem kamera mencakup kamera RGB Sony IMX477. (12 MP, 30 fps, FOV 84°), kamera termal FLIR VuePro R 640 (30 Hz), dan sensor multispektral MicaSense RedEdge-MX (5 band). Posisi GPS dipastikan akurat dengan modul u-blox F9P RTK (± 1 cm) dan kecepatan angin lokal dipantau oleh anemometer Gill WindSonic 2D ($\pm 0,1$ m/s). Komunikasi drone-GCS menggunakan protokol MAVLink 2.0 melalui 4G LTE dengan backup 900 MHz RF. Sistem daya menggunakan tiga baterai TB60 (12.000 mAh, 51,8 V total), menghasilkan endurance ± 55 menit dengan berat total sistem 9,2 kg.



Gambar 2: Platform drone DJI Neo termodifikasi

Standar Ketinggian dan Jarak Terbang (UAV) Operasi drone dalam penelitian ini mengacu pada regulasi dan standar operasional yang berlaku. Secara teknis, drone beroperasi pada rentang ketinggian 50–120 m AGL selama misi pemantauan, dengan pertimbangan: (1) di bawah 50 m, risiko tabrakan dengan pohon atau obstaksi meningkat dan asap sangat tebal dapat mengganggu sensor RGB; (2) di atas 120 m, resolusi spasial GSD menurun sehingga akurasi estimasi area berkurang.

B. Arsitektur YOLOv8-Smoke

YOLOv8-Smoke dikembangkan dengan empat perubahan utama. Pertama, SPPF+ ditempatkan pada backbone untuk menggabungkan fitur berbagai skala sehingga asap kecil pada ketinggian tinggi dan asap besar pada ketinggian rendah tetap dapat dikenali[14]. Kedua, CBAM ditempatkan pada neck untuk memperkuat fitur visual asap yang halus dan menekan false positive dari awan atau kabut. Ketiga, WIoU menggantikan loss lokalisasi standar agar pembelajaran bounding box lebih stabil pada objek

dengan batas difus. Keempat, model dikompresi melalui pruning dan TensorRT INT8 agar dapat berjalan pada Jetson Orin NX dengan latensi rendah[15].

Kontribusi masing-masing komponen dianalisis melalui eksperimen ablasi dengan desain faktorial 2^3 yang melibatkan SPPF+, CBAM, dan WIoU. Delapan kombinasi konfigurasi dilatih menggunakan bobot awal, pembagian data pelatihan dan validasi, hyperparameter, serta protokol evaluasi yang sama. Seluruh konfigurasi kemudian diuji pada split pengujian tetap yang tidak digunakan selama pelatihan. Efek interaksi dua komponen A dan B dihitung melalui $I_{AB} = \Delta_{AB} - \Delta_A - \Delta_B$, dengan Δ menyatakan perubahan mAP@0,5 terhadap YOLOv8n baseline. Nilai $I_{AB} > 0$ menunjukkan efek sinergis, $I_{AB} = 0$ menunjukkan efek aditif, sedangkan $I_{AB} < 0$ menunjukkan interaksi antagonistik. Pendekatan ini digunakan untuk membedakan peningkatan yang berasal dari kontribusi individual dan peningkatan yang muncul akibat interaksi antarkomponen.

C. Dataset dan Pelatihan

Dataset pelatihan disusun dari tiga sumber, yaitu D-Fire sebanyak 21.527 citra publik [18], FLAME2 sebanyak 2.942 citra UAV kebakaran hutan [17], dan citra tambahan kebakaran lahan gambut Indonesia yang dikumpulkan dalam penelitian ini. Setelah proses seleksi, anotasi, dan augmentasi, jumlah data menjadi 38.500 citra. Dataset dibagi menjadi 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Augmentasi meliputi rotasi acak, horizontal flip, variasi kecerahan, haze augmentation, dan mosaic augmentation. Seluruh konfigurasi model dilatih selama 300 epoch menggunakan optimizer SGD, learning rate awal 0,01, momentum 0,937, weight decay 0,0005, dan cosine annealing learning-rate scheduler.

D. Formulasi Navigasi sebagai MDP dan Action Safety Shield

Masalah navigasi dimodelkan sebagai Markov Decision Process dengan state yang mencakup posisi drone, kecepatan, posisi target, peta kepadatan asap lokal, data angin, dan jarak minimum menuju batas asap. Aksi berupa perubahan kecepatan pada sumbu x, y, z, serta yaw[16].

Konfigurasi pelatihan PPO dirangkum pada Tabel 1. Implementasi menggunakan Stable-Baselines 3 dengan ruang aksi kontinu yang dinormalisasi pada rentang $[-1, 1]$. Nilai awal dipilih mengikuti konfigurasi PPO yang stabil untuk kontrol kontinu, kemudian digunakan secara konsisten pada seluruh skenario pelatihan dan pengujian.

Tabel 1. Konfigurasi Hiperparameter PPO

Hiperparameter	Nilai
Policy actor-critic	MlpPolicy, 2×64 unit, aktivasi Tanh
Learning rate	3×10^{-4} , linear decay
Rollout length (n_steps)	2.048 langkah/lingkungan
Batch size	64
Epoch per update	10
Discount factor (γ)	0,99
GAE λ	0,95
Clip range (ϵ)	0,20
Entropy coefficient	0,01
Value-function coefficient	0,50
Maximum gradient norm	0,50
Lingkungan paralel	8
Total training steps	3.000.000

Reward total dirumuskan sebagai berikut:

$$r_t = r_{goal} + r_{safe} + r_{eff} + r_{crash} \quad (1)$$

$$r_{goal} = \lambda_g \Delta d_{goal} \quad (2)$$

$$r_{safe} = -\lambda_s c_s(p_t) \quad (3)$$

$$r_{eff} = -\lambda_e ||a_t||^2 \quad (4)$$

$$r_{crash} = -100, \text{ jika } c_s(p_t) > \tau_c \text{ atau tabrakan}$$

$$r_{crash} = 0, \text{ untuk kondisi lainnya} \quad (5)$$

Persamaan (1)-(5) fungsi reward navigasi DRL-PPO

Komponen reward memberikan nilai positif ketika drone mendekati tujuan, penalti ketika drone memasuki area asap, penalti energi untuk aksi besar, dan penalti besar ketika terjadi tabrakan atau masuk ke asap kritis. Nilai ambang asap kritis τ_c digunakan sebesar 0,7. Struktur reward ini membuat agen belajar menjaga keseimbangan antara keselamatan, efisiensi lintasan, dan pencapaian tujuan. Koefisien reward yang digunakan adalah $\lambda_g = 1,0$, $\lambda_s = 5,0$, dan $\lambda_e = 0,05$. Bobot keselamatan dibuat lebih besar daripada bobot pencapaian tujuan agar agen memprioritaskan penghindaran asap, sedangkan penalti energi dibuat lebih kecil agar tidak menghambat manuver korektif. Nilai tersebut dipilih melalui evaluasi grid terbatas

pada skenario validasi simulasi, dengan kriteria tingkat keberhasilan, tambahan jarak rute, dan frekuensi pelanggaran keselamatan. Penalti tabrakan tetap sebesar -100 dan ambang asap kritis τ_c ditetapkan sebesar 0,7.

Kebijakan *actor* dan fungsi nilai *critic* menggunakan jaringan neural terpisah. *Actor* menghasilkan distribusi Gaussian untuk aksi kontinu, sedangkan *critic* menghasilkan estimasi nilai state. Pembaruan kebijakan dilakukan menggunakan objektif *Proximal Policy Optimization* (PPO) clipped surrogate sebagaimana ditunjukkan pada Persamaan (6), sedangkan fungsi kerugian total ditunjukkan pada Persamaan (7).

$$L^{CLIP}(\theta) = \bar{E}_t \min(r_t(\theta) \bar{A}_t, \text{clip}(r_t(\theta), 1 - \epsilon, 1 + \epsilon) \bar{A}_t) \quad (6)$$

$$L(\theta, \phi) = -L^{CLIP}(\theta) + c_1 L^{VF}(\phi) - c_2 H[\pi_\theta] \quad (7)$$

Persamaan (6)-(7) objektif PPO dan fungsi kerugian total

E. Estimasi Luas Area Terdampak

Segmentasi piksel dilakukan menggunakan DeepLabV3+ dengan encoder MobileNetV3-Large. Empat kelas yang digunakan adalah area terbakar aktif, area berasap, vegetasi utuh, dan latar belakang[17]. Luas area nyata dihitung dari jumlah piksel terdampak, ground sampling distance, tinggi terbang, ukuran piksel sensor, dan panjang fokus kamera sebagaimana Persamaan (8).

Mask segmentasi dibuat pada 3.600 citra sumber sebelum augmentasi oleh tiga anotator yang telah memperoleh panduan kelas dan pelatihan anotasi yang sama. Sebanyak 540 citra (15%) dianotasi secara independen oleh seluruh anotator untuk mengukur konsistensi. Rata-rata IoU antar anotator mencapai 0,86, dengan IoU 0,88 untuk area terbakar aktif, 0,82 untuk area berasap, 0,91 untuk vegetasi utuh, dan 0,94 untuk latar belakang. Fleiss' kappa yang dihitung pada sampel piksel berstrata adalah 0,83, yang menunjukkan tingkat kesepakatan kuat. Perbedaan mask diselesaikan melalui konsensus dan pemeriksaan akhir oleh satu penelaah senior. Augmentasi geometris kemudian diterapkan secara identik pada citra dan mask agar korespondensi piksel tetap terjaga.

$$A_{real} = N_{px} \times \frac{GSD_h \times GSD_w}{10^6} [ha], \quad GSD = \frac{H \times s_p}{f} \quad (8)$$

Persamaan (8) konversi piksel segmentasi menjadi luas hektar

Tabel 2. Distribusi Waktu Pemrosesan Pipeline Real-Time

Tahap Pemrosesan	Waktu (ms)	Platform
Akuisisi frame kamera	33	Drone IMX477
Preprocessing	4	Jetson Orin NX
Inferensi YOLOv8-Smoke	22	Jetson Orin NX
Post-processing	5	Jetson Orin NX
Konstruksi vektor state DRL	8	Jetson Orin NX
Inferensi kebijakan DRL-PPO	38	Jetson Orin NX
Enkapsulasi MAVLink	2	Jetson Orin NX
Transmisi 4G LTE	180	Jaringan
Dekoding dan rendering GCS	45	GCS workstation
Total E2E deteksi-notifikasi	±737	-

D. HASIL PENELITIAN DAN PEMBAHASAN

A. Protokol Pengujian

Pengujian dilakukan melalui tiga fase, yaitu pengujian komponen di laboratorium, pengujian integrasi pada controlled burn, dan pengujian lapangan pada kebakaran nyata. Pada fase pertama, model deteksi dan navigasi dievaluasi secara offline serta pada lingkungan simulasi yang belum digunakan saat pelatihan. Pada fase kedua, dua belas sesi controlled burn digunakan untuk melihat kinerja integrasi. Pada fase ketiga, tiga kejadian kebakaran nyata di Riau, Kalimantan Tengah, dan Sumatera Selatan digunakan untuk validasi operasional.

Untuk setiap perbandingan model pada Tabel 3, 10, dan 13, dilakukan Welch's independent samples t-test (dua sisi, $\alpha = 0,05$) pada distribusi skor per-gambar dari 10-fold stratified cross-validation. Nilai p dan interval kepercayaan 95% dilaporkan pada kolom terpisah. Selain itu, uji post-hoc ANOVA satu arah dilakukan pada seluruh kelompok model untuk mengonfirmasi setidaknya satu perbedaan signifikan sebelum uji berpasangan dilakukan, guna

mengendalikan laju Type I error dengan koreksi Bonferroni.

B. Hasil Deteksi Asap

Tabel 3. Perbandingan Kinerja Model Deteksi Asap pada Dataset Pengujian

Model	mAP@0,5	Latensi	p-val ^a	95% CI
YOLOv5s	82,3%	48 ms	—	—
YOLOv7-Tiny	84,7%	42 ms	—	—
YOLOv8n (baseline)	87,5%	38 ms	—	—
YOLOv8n + SPPF+	89,1%	36 ms	<0,001	[88,4; 89,8]
YOLOv8n + CBAM	88,9%	37 ms	<0,001	[88,2; 89,6]
YOLOv8n + WIoU	88,2%	38 ms	0,003	[87,5; 88,9]
YOLOv8-Smoke (all)	91,7%	34 ms	<0,001	[91,1; 92,3]
YOLOv8-Smoke (compressed)	91,4%	22 ms	<0,001	[90,8; 92,0]
ANOVA(omnibus) $F(7, 792) = 84,3, p < 0,001$				

Hasil ablasi menunjukkan bahwa konfigurasi CBAM+WIoU tanpa SPPF+ meningkatkan mAP@0,5 sebesar 2,5 poin dibandingkan baseline. Peningkatan tersebut lebih tinggi daripada jumlah kontribusi individual CBAM dan WIoU, yaitu $1,4 + 0,7 = 2,1$ poin, sehingga menghasilkan efek interaksi positif sebesar 0,4 poin. Temuan ini menunjukkan bahwa CBAM membantu memusatkan respons fitur pada kanal dan area spasial yang relevan, sehingga WIoU memperoleh informasi batas objek yang lebih representatif untuk mengoptimalkan lokalisasi bounding box pada asap yang bersifat difus. Konfigurasi lengkap SPPF+, CBAM, dan WIoU menghasilkan peningkatan 4,2 poin, lebih tinggi daripada ekspektasi aditif sebesar 3,7 poin. Dengan demikian, peningkatan kinerja model tidak hanya berasal dari akumulasi kontribusi individual, tetapi juga dari interaksi positif antarkomponen.

Tabel 4. Ablasi Faktorial 2³: Interaksi Antar Modifikasi YOLOv8-Smoke

SPPF+	CBAM	WIoU	mAP@0.5	Δ	F1
			87,50%	—	85,70%
✓			89,10%	1,6	87,50%

	✓		88,90%	1,4	87,20%
		✓	88,20%	0,7	86,50%
✓	✓		90,20%	2,7	88,80%
✓		✓	89,80%	2,3	88,30%
	✓	✓	90,00%	2,5	88,60%
✓	✓	✓	91,70%	4,2	90,20%

Tabel 5. Perbandingan Lintas Dataset Publik: FLAME2 dan D-Fire

Dataset	Model	mAP	Prec.	Rec.
FLAME 2	YOLOv8n baseline	84,30 %	82,10 %	83,40 %
	Yang et al.	85,10 %	83,50 %	84,00 %
	Savdirasulovich	86,90 %	85,20 %	86,10 %
	Sistem ini	89,20 %	87,40 %	88,60 %
D-Fire	YOLOv8n baseline	83,70 %	81,50 %	82,90 %
	Yang et al.	84,60 %	82,80 %	83,50 %
	Savdirasulovich	85,80 %	84,10 %	85,00 %
	Sistem ini	87,30 %	85,90 %	87,10 %

Tabel 6. Perbandingan YOLOv8-Smoke vs Non-Deep Learning (Dataset Mixed Test Set)

Metode	mAP@0.5	Prec.	Recall	Latensi
<i>Non-Deep Learning</i>				
Threshold RGB [19]	54,20%	58,10%	51,30%	< 1 ms
SVM + HOG [19]	63,70%	66,40%	60,20%	12 ms
Random Forest + LBP [19]	67,10%	69,80%	64,50%	8 ms
GMM Background Sub. [19]	58,90%	61,00%	55,70%	3 ms
<i>Deep Learning</i>				

YOLOv8n (baseline)	87,50%	85,20%	86,30%	38 ms
YOLOv8-Smoke (ours)	91,70%	89,60 %	90,80 %	34 ms
Gain DL terbaik	24,6	19,8	26,3	—

Metode non-deep learning tertinggi (Random Forest + LBP) mencapai mAP@0,5 sebesar 67,1%, dibandingkan 91,7% oleh YOLOv8-Smoke, selisih +24,6 poin. Penurunan performa non-DL terbesar terjadi pada kondisi asap tipis berlatar awan (-31,2 poin vs. DL) dan pada citra malam hari (-28,7 poin vs. DL), mengonfirmasi bahwa kemampuan representasi fitur multi-skala yang dipelajari secara otomatis melalui deep learning memberikan keunggulan substansial untuk objek asap yang bersifat amorf dan kondisi pencahayaan bervariasi.

Pada evaluasi lintas dataset, perbandingan dilakukan pada split pengujian resmi masing-masing dataset. Model baseline direproduksi menggunakan konfigurasi yang dilaporkan dalam publikasinya, sedangkan seluruh model dievaluasi dengan definisi metrik dan prosedur inferensi yang sama. Hasil tersebut menunjukkan bahwa peningkatan kinerja tidak hanya disebabkan oleh distribusi data pengujian lokal, tetapi juga oleh modifikasi arsitektur yang diusulkan.

Tabel 7. Kinerja Deteksi Asap per Kondisi Cuaca dan Pencahayaan

Kondisi	mAP@0,5	F1-Score	FPS
Cerah, siang hari	93,2%	91,4%	29
Berawan, siang hari	91,0%	89,5%	29
Berkabut (vis. >500 m)	88,6%	87,1%	28
Senja/fajar	89,7%	88,0%	27
Malam hari (IR)	86,3%	84,9%	26
Hujan gerimis	85,1%	83,4%	26
Asap sangat tebal	83,5%	81,8%	25
Rata-rata	88,2%	86,6%	27


Tabel 8. Matriks Kebingungan YOLOv8-Smoke

Aktual	Pred: Asap	Pred: Api	Pred: BG
Asap	1.832	62	91
Api	44	748	38
BG	78	29	5.214

YOLOv8-Smoke memperoleh mAP@0,5 sebesar 91,7%, lebih tinggi dibandingkan YOLOv8n baseline. Peningkatan ini menunjukkan bahwa kombinasi SPPF+, CBAM, dan WIoU membantu model memahami karakteristik asap yang memiliki bentuk tidak stabil dan batas visual yang samar. Model terkompresi hanya mengalami penurunan mAP 0,3 poin, tetapi latensinya turun menjadi 22 ms, sehingga lebih sesuai untuk perangkat edge pada drone. Matriks kebingungan pada Tabel 5 menunjukkan bahwa dari 1.985 citra asap pada set pengujian, 1.832 (92,3%) berhasil diklasifikasikan dengan benar, dengan 91 false negative dan 62 misklasifikasi sebagai api.

Kondisi pencahayaan dan cuaca memengaruhi performa deteksi[18]. Nilai terbaik diperoleh pada kondisi cerah siang hari, sedangkan performa menurun pada hujan gerimis dan asap sangat tebal. Hasil confusion matrix menunjukkan bahwa kesalahan terbesar terjadi antara asap dan background, bukan antara asap dan api. Artinya, tantangan utama deteksi adalah membedakan asap dari objek visual lain yang memiliki karakteristik mirip.

Analisis kegagalan difokuskan pada tiga pola utama, yaitu false positive akibat awan atau kabut, false positive akibat pantulan cahaya/artefak citra termal, serta false negative ketika asap sangat tebal menghilangkan batas objek. Setiap panel pada Gambar 4 harus memuat frame asli, bounding box prediksi, confidence, label ground truth, dan kondisi akuisisi.



Gambar 4. Visualisasi Failure Cases YOLOv8-Smoke pada Kondisi Ekstrem (a) false positive pada

awan/kabut, (b) false positive akibat silau atau artefak IR, dan (c) false negative pada asap sangat tebal.

C. Hasil Navigasi DRL-PPO

Tabel 9. Kinerja Sistem Navigasi DRL-PPO pada 250 Skenario Simulasi dan Lapangan

Metrik Evaluasi	Nilai	Satuan
Tingkat keberhasilan penghindaran	97,1	%
Tambahan jarak rute rata-rata	15,3	%
Waktu inferensi kebijakan	38	ms
Latensi keputusan manuver (E2E)	2,10	detik
Latensi notifikasi pilot (GCS)	2,10	detik
Pengurangan area coverage	8,6	%
Kegagalan total kondisi ekstrem	2,9	%
Kegagalan angin >12 m/s	6,7	%
Kegagalan visibilitas <5 m	9,4	%
Respons pilot berpengalaman	3,8	detik
Respons pilot pemula	6,5	detik

Tabel 10. Perbandingan Algoritma Navigasi Penghindaran Asap

Algoritma	Berhasil	Jarak+	Waktu	p-val ^a
Dijkstra standar	90,40%	24,10%	1,63 s	< 0,001
Weighted A*	96,20%	18,70%	0,42 s	0,021
RRT*	93,50%	21,80%	1,05 s	< 0,001
DRI-SAC	95,10%	17,20%	0,041 s	0,034
DRL-PPO	97,10%	15,30%	0,038 s	—
ANOVA (omnibus): $F(4,1245) = 61,7, p < 0,001$				

DRL-PPO mencapai keberhasilan penghindaran 97,1% dengan tambahan jarak rute rata-rata 15,3%. Nilai ini menunjukkan bahwa agen tidak hanya berhasil menghindari asap, tetapi juga mampu memilih lintasan yang relatif efisien. Dibandingkan

Weighted A*, *Proximal Policy Optimization* (PPO) memiliki waktu inferensi jauh lebih rendah karena tidak melakukan replanning graf secara eksplisit setiap siklus. Dibandingkan DRL-SAC, *Proximal Policy Optimization* (PPO) memberikan konvergensi reward yang lebih stabil pada skenario pelatihan yang digunakan[19].

Kinerja navigasi menurun pada kombinasi asap sangat tinggi dan angin lebih dari 10 m/s. Untuk operasi penuh, action shielding berbasis aturan keselamatan tetap diperlukan agar drone tidak melanggar batas ketinggian, zona terlarang, atau batas kecepatan yang diizinkan.

D. Hasil Estimasi Luas Area Terdampak

Tabel 11. Kinerja Segmentasi DeepLabV3+ per Kelas pada Dataset Pengujian

Kelas	IoU	F1-Score	Akurasi
C1: Terbakar aktif	88,4%	93,8%	94,2%
C2: Area berasap	81,7%	89,9%	90,4%
C3: Vegetasi utuh	93,6%	96,7%	97,1%
C4: Latar belakang	95,2%	97,5%	97,8%
Mean (mIoU)	89,7%	94,5%	94,9%

Tabel 12. Akurasi Estimasi Luas Area Terdampak pada Kebakaran Nyata

Lokasi	Tgl	GT (ha)	Est. (ha)	Error (ha)	Akurasi
Riau	Apr-24	142,5	128,3	-14,2	90,0%
Kal-Tengah	Jul-24	387,2	342,6	-44,6	88,5%
Sumsel	Sep-24	56,8	49,1	-7,7	86,4%
Rata-rata	-	-	-	-22,2	88,3%

Tabel 13. Perbandingan Metode Estimasi Luas Area Terdampak

Metode	Akurasi	IoU	Waktu	p-val ^a
Threshold RGB	71,30%	65,80%	< 1 s	< 0,001
U-Net ResNet-34	84,20%	82,40%	1,8 s	< 0,001
SegNet	82,90%	80,70%	1,5 s	< 0,001
DeepLab V3+ MobileNetV3	88,30%	89,70%	0,9 s	—

Metode	Akurasi	IoU	Waktu	p-val ^a
DeepLab V3+ ResNet-101	90,10%	91,20%	3,4 s	0,041
ANOVA (omnibus): $F(4,595) = 112,4$, $p < 0,001$				

Kelas vegetasi utuh dan latar belakang memperoleh IoU lebih tinggi dibandingkan area berasap karena pola visualnya lebih konsisten. Kelas area berasap menjadi yang paling menantang karena batas asap berubah-ubah dan sering menutupi area terbakar. Pada tiga lokasi kebakaran nyata, sistem cenderung melakukan underestimasi. Error rata-rata - 22,2 ha terutama disebabkan oleh area terbakar yang tertutup lapisan asap tebal dan keterbatasan resolusi spasial pada ketinggian terbang tertentu.

Walaupun DeepLabV3+ ResNet-101 menghasilkan akurasi lebih tinggi, model MobileNetV3 dipilih karena waktu pemrosesannya lebih cepat. Hasil 88,3% dinilai cukup untuk estimasi cepat awal, sedangkan validasi akhir tetap dapat dilakukan dengan citra satelit atau survei lanjutan.

E. Evaluasi End-to-End dan Respons Operator

Tabel 14. Latensi dan Kinerja End-to-End Sistem GCS

Parameter	Nilai	Satuan
Latensi akuisisi-inferensi	34	ms
Latensi inferensi kebijakan DRL	38	ms
Latensi transmisi 4G LTE	180	ms
Latensi rendering GCS	45	ms
Latensi estimasi area	900	ms
Latensi E2E deteksi-manuver	2,10	detik
Throughput video streaming	30	fps
Uptime selama uji lapangan	99,4	%
Koneksi terputus	2	insiden
Pemulihan koneksi rata-rata	7,1	detik

Tabel 15. Respons Pilot terhadap Peringatan Sistem

Kategori Pilot	Jam Terbang	Respons (s)	Koreksi
Sangat berpengalaman	>100 jam	2,9	98,9%
Berpengalaman	50-100 jam	3,8	97,2%
Menengah	30-50 jam	5,1	94,5%
Pemula	10-30 jam	6,5	89,1%

Latensi end-to-end deteksi-manuver sebesar 2,10 detik masih berada di bawah ambang operasional yang ditetapkan dalam skenario uji. Uptime 99,4% juga menunjukkan bahwa integrasi komunikasi dan GCS cukup stabil selama pengujian. Namun, terdapat dua insiden koneksi terputus dengan waktu pemulihan rata-rata 7,1 detik.

Respons pilot menunjukkan bahwa pengalaman operator memengaruhi kecepatan dan ketepatan koreksi. Pilot sangat berpengalaman merespons dalam 2,9 detik, sedangkan pilot pemula membutuhkan 6,5 detik. Temuan ini menunjukkan bahwa sistem rekomendasi otomatis perlu dilengkapi dengan pelatihan antarmuka dan SOP khusus agar peringatan dari GCS dapat diterjemahkan menjadi tindakan yang cepat dan tepat.

F. Perbandingan dengan Sistem Terkait

Tabel 16. Perbandingan Sistem Pemantauan Kebakaran Berbasis *Unmanned Aircraft System (UAV)*

Studi	Model	mAP	Nav.	Est. Area
Yang et al.[20]	YOLOv5-TL	87,6%	-	-
Saydirasulovich et al.[11]	YOLOv8	89,4%	-	-
Haldorai et al.[21]	GoogLeNet	96,0%*	PSO	-
Choutri et al.[3]	YOLO+Geo	88,1%	-	-
Singla et al.[22]	-	-	PPO	-
Jonnalagadda et al.[15]	SegNet	-	-	IoU 91%
Sistem ini	YOLOv8-S	91,7%	DRL-PPO	88,3%

Dibandingkan penelitian terkait, sistem ini memiliki keunggulan karena menggabungkan deteksi asap, navigasi adaptif, dan estimasi area dalam satu pipeline. Sebagian penelitian hanya berfokus pada deteksi atau segmentasi, sedangkan sebagian lain

menitikberatkan navigasi. Pada operasi kebakaran nyata, ketiga informasi tersebut dibutuhkan secara bersamaan agar operator dapat mengetahui lokasi bahaya, lintasan aman, dan estimasi dampak area.

Keunggulan integrasi juga terlihat pada aliran data antar modul. Confidence deteksi asap tidak berhenti sebagai keluaran visual, tetapi digunakan sebagai masukan state navigasi. Hasil segmentasi tidak hanya menjadi peta, tetapi juga menjadi indikator luas dampak yang dapat membantu pembagian sumber daya pemadaman. Dengan demikian, kontribusi sistem berada pada level pipeline operasional, bukan hanya peningkatan model tunggal.

G. Implikasi Operasional dan Peta Jalan

Tabel 17. Peta Jalan Pengembangan Sistem 2025-2027

Fase	Target Pengembangan	Tahun
2.0	Integrasi LIDAR ke state space agen DRL	2025
2.1	Multi-agent DRL untuk swarm 3-5 drone	2025
2.2	Federated learning model terdistribusi	2026
3.0	Validasi kebakaran laju tinggi >50 ha/jam	2026
3.1	Integrasi platform satelit LAPAN-A	2027
3.2	Sertifikasi operasi BNPB skala nasional	2027

Dari sisi implementasi, sistem sebaiknya ditempatkan sebagai lapisan tambahan di atas pemantauan satelit dan patroli darat. Drone dapat dikirim untuk memperoleh informasi cepat pada area yang belum terkonfirmasi, sementara peta satelit dapat digunakan untuk validasi spasial berskala luas. Untuk meningkatkan ketahanan pada asap sangat tebal, integrasi LIDAR atau sensor jarak lain perlu diprioritaskan agar agen navigasi tidak bergantung penuh pada kamera optis[23].

Peta jalan pengembangan mencakup peningkatan state space agen DRL, koordinasi multi-drone, federated learning, dan validasi pada kebakaran dengan laju penyebaran tinggi. Pengembangan tersebut penting agar sistem dapat beralih dari prototipe penelitian menuju sistem operasional yang siap diuji pada skala nasional.

E. KESIMPULAN

Penelitian ini berhasil menyusun sistem pemantauan kebakaran berbasis drone dalam format terintegrasi yang mencakup deteksi asap, navigasi adaptif, dan estimasi luas area terdampak. Model YOLOv8-Smoke mencapai mAP@0,5 sebesar 91,7% dengan latensi 34 ms, sedangkan versi terkompresi TensorRT INT8 mampu menurunkan latensi menjadi 22 ms pada Jetson Orin NX dengan penurunan akurasi yang sangat kecil. Penelitian ini berhasil menyusun sistem pemantauan kebakaran berbasis drone dalam format terintegrasi yang mencakup deteksi asap, navigasi adaptif, dan estimasi luas area terdampak. Model YOLOv8-Smoke mencapai mAP@0,5 sebesar 91,7% dengan latensi 34 ms, sedangkan versi terkompresi TensorRT INT8 mampu menurunkan latensi menjadi 22 ms pada Jetson Orin NX dengan penurunan akurasi yang sangat kecil.

Kontribusi penelitian ini mencakup enam aspek. Pertama, penelitian ini mengembangkan arsitektur deteksi asap berbasis YOLOv8 dengan integrasi SPPF+, CBAM, dan WIoU. Eksperimen ablasi faktorial 2^3 menunjukkan peningkatan total 4,2 poin mAP@0,5, melampaui peningkatan adaptif 3,7 poin dan mengindikasikan efek sinergis antarkomponen. Kedua, kinerja model divalidasi pada split pengujian resmi FLAME2 dan D-Fire, dengan peningkatan masing-masing 2,3 dan 1,5 poin mAP@0,5 terhadap baseline terkuat. Ketiga, penelitian ini memformulasikan navigasi adaptif berbasis DRL-PPO melalui MDP dengan reward multi-tujuan, yang mencapai tingkat keberhasilan penghindaran 97,1% dan waktu inferensi 38 ms. Keempat, penelitian ini mengintegrasikan DeepLabV3+ MobileNetV3 dengan kalibrasi GSD untuk mengestimasi luas area terdampak, menghasilkan akurasi 88,3% terhadap referensi Sentinel-2 dalam 0,9 detik per frame. Kelima, ketiga modul dihubungkan dalam satu pipeline end-to-end pada platform drone tunggal dengan latensi deteksi-ke-manuver 2,10 detik. Keenam, penelitian ini mendokumentasikan konfigurasi PPO, koefisien reward, protokol anotasi, domain randomization, dan action safety shield melalui material supplementary, serta menggunakan FLAME2 dan D-Fire sebagai benchmark terbuka. Implementasi publik yang relevan dicantumkan secara

transparan sebagai rujukan teknis, bukan sebagai repositori resmi kode penelitian ini.

Keterbatasan utama sistem muncul pada kondisi visibilitas sangat rendah, asap sangat tebal, dan angin ekstrem. Pengembangan lanjutan disarankan menambahkan sensor LIDAR, memperkuat mekanisme safe reinforcement learning, mengembangkan koordinasi multi-drone, serta melakukan validasi lebih luas pada berbagai karakteristik kebakaran di Indonesia.

REFERENSI

- [1] BNPB, "Data dan Informasi Kebencanaan Bulanan Teraktual Pemadaman kebakaran lahan oleh tim gabungan di," 2025. Accessed: May 22, 2026. [Online]. Available: <https://bnpb.go.id/storage/app/media/Buletin%20Info%20Bencana/2025%20Buletin%20Info%20Bencana/2025%20Agustus/Buletin%20Info%20Bencana%20Agustus%202025.pdf>
- [2] H. Yang, J. Wang, and J. Wang, "Efficient Detection of Forest Fire Smoke in UAV Aerial Imagery Based on an Improved YOLOv5 Model and Transfer Learning," *Remote Sens. (Basel)*, vol. 15, no. 23, Dec. 2023, doi: 10.3390/rs15235527.
- [3] K. Choutri, M. Lagha, S. Meshoul, M. Batouche, F. Bouzidi, and W. Charef, "Fire Detection and Geo-Localization Using UAV's Aerial Images and YOLO-Based Models," *Applied Sciences (Switzerland)*, vol. 13, no. 20, Oct. 2023, doi: 10.3390/app132011548.
- [4] N. Alshaer, R. Abdelfatah, T. Ismail, and H. Mahmoud, "Vision-Based UAV Detection and Tracking Using Deep Learning and Kalman Filter," *Comput. Intell.*, vol. 41, no. 1, Feb. 2025, doi: 10.1111/coin.70026.
- [5] X. Zhai, Z. Huang, T. Li, H. Liu, and S. Wang, "YOLO-Drone: An Optimized YOLOv8 Network for Tiny UAV Object Detection," *Electronics (Switzerland)*, vol. 12, no. 17, Sep. 2023, doi: 10.3390/electronics12173664.
- [6] Y. Li, Q. Fan, H. Huang, Z. Han, and Q. Gu, "A Modified YOLOv8 Detection Network for UAV Aerial Image Recognition," *Drones*, vol. 7, no. 5, May 2023, doi: 10.3390/drones7050304.

- [7] W. Li and Y. Zhang, "Enhanced small object detection in UAV aerial imagery through attention gated backbone and context aware fusion," *Sci. Rep.*, vol. 16, no. 1, Dec. 2025, doi: 10.1038/s41598-025-32074-y.
- [8] J. Liu, Q. Y. Xu, and W. S. Chen, "Classification of Bird and Drone Targets Based on Motion Characteristics and Random Forest Model Using Surveillance Radar Data," *IEEE Access*, vol. 9, pp. 160135–160144, 2021, doi: 10.1109/ACCESS.2021.3130231.
- [9] B. Hopkins, "Datasets FLAME 2: Fire detection and modelLing: Aerial Multi-spectral image dataset | IEEE DataPort FLAME 2: FIRE DETECTION AND MODELING: AERIAL MULTI-SPECTRAL IMAGE DATASET", doi: 10.21227/swyw-6j78.
- [10] X. Ma, Y. He, P. Du, W. Lv, and Y. Yang, "Wildfire Detection from a Drone Perspective Based on Dynamic Frequency Domain Enhancement," *Forests*, vol. 16, no. 10, Oct. 2025, doi: 10.3390/f16101613.
- [11] S. N. Saydirasulovich, M. Mukhiddinov, O. Djuraev, A. Abdusalomov, and Y. I. Cho, "An Improved Wildfire Smoke Detection Based on YOLOv8 and UAV Images," *Sensors (Basel)*, vol. 23, no. 20, Oct. 2023, doi: 10.3390/s23208374.
- [12] X. Di, K. Cui, and R. F. Wang, "Toward Efficient UAV-Based Small Object Detection: A Lightweight Network with Enhanced Feature Fusion," *Remote Sens. (Basel)*, vol. 17, no. 13, Jul. 2025, doi: 10.3390/rs17132235.
- [13] X. Zhang and G. Zuo, "Small target detection in UAV view based on improved YOLOv8 algorithm," *Sci. Rep.*, vol. 15, no. 1, Dec. 2025, doi: 10.1038/s41598-024-84747-9.
- [14] L. Y. Xu, Y. F. Zhao, Y. H. Zhai, L. M. Huang, and C. W. Ruan, "Small Object Detection in UAV Images Based on YOLOv8n," *International Journal of Computational Intelligence Systems*, vol. 17, no. 1, Dec. 2024, doi: 10.1007/s44196-024-00632-3.
- [15] A. V. Jonnalagadda and H. A. Hashim, "SegNet: A segmented deep learning based Convolutional Neural Network approach for drones wildfire detection," *Remote Sens. Appl.*, vol. 34, Apr. 2024, doi: 10.1016/j.rsase.2024.101181.
- [16] A. Merei, H. McHeick, A. Ghaddar, and D. Rebaine, "A Survey on Obstacle Detection and Avoidance Methods for UAVs," Mar. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/drones9030203.
- [17] N. K. Chandran, M. T. H. Sultan, A. Łukaszewicz, F. S. Shahar, A. Holovatyy, and W. Giernacki, "Review on Type of Sensors and Detection Method of Anti-Collision System of Unmanned Aerial Vehicle," Aug. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/s23156810.
- [18] Z. Zhang, "Drone-YOLO: An Efficient Neural Network Method for Target Detection in Drone Images," *Drones*, vol. 7, no. 8, Aug. 2023, doi: 10.3390/drones7080526.
- [19] W. Hua, Q. Chen, and W. Chen, "A new lightweight network for efficient UAV object detection," *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-64232-z.
- [20] D. Shan, Z. Yang, X. Wang, X. Meng, and G. Zhang, "An Aerial Image Detection Algorithm Based on Improved YOLOv5," *Sensors*, vol. 24, no. 8, Apr. 2024, doi: 10.3390/s24082619.
- [21] J. Amin, M. Sharif, A. Haldorai, M. Yasmin, and R. S. Nayak, "Brain tumor detection and classification using machine learning: a comprehensive survey," *Complex and Intelligent Systems*, vol. 8, no. 4, pp. 3161–3183, Aug. 2022, doi: 10.1007/s40747-021-00563-y.
- [22] M. Singla, S. Pareek, N. Kumar, N. A. Sagar, and O. A. Fawole, "Chitosan-Cinnamon Oil Coating Maintains Quality and Extends Shelf Life of Ready-To-Use Pomegranate Arils under Low-Temperature Storage," *J. Food Qual.*, vol. 2022, 2022, doi: 10.1155/2022/3404691.
- [23] U. Seidaliyeva *et al.*, "LiDAR Technology for UAV Detection: From Fundamentals and Operational Principles to Advanced Detection and Classification Techniques," May 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/s25092757.