



Pengembangan Model Hibrida AI untuk Manipulasi Aerial yang Kompleks

Aditya Nugraha Pratama^{1*}, Bella Safira Azzahra²

^{1,2} Universitas Bina Nusantara, Indonesia

Email : aditya.pratama@binus.ac.id^{1*}, bella.azzahra@binus.ac.id²

Alamat: POJ Avenue No.Kav. 3, Tawang Sari, Kec. Semarang Barat, Kota Semarang

Korespondensi penulis : aditya.pratama@binus.ac.id

Abstract. *This research aims to develop a hybrid artificial intelligence model to enable aerial vehicles (drones) to perform complex and agile manipulation maneuvers in dynamic environments. Conventional approaches based on physical models often fail to handle uncertainties and non-linearities when interacting with objects in the air. Therefore, we propose a hybrid AI architecture that combines Deep Reinforcement Learning (DRL) for real-time decision-making with physical Neural Networks or modified Model Predictive Control (MPC) to ensure stability and trajectory precision. The model is trained in a simulation environment that represents aerodynamic forces and unexpected contacts. Simulation results show that the proposed hybrid model achieves higher success rates in manipulation tasks and faster task completion times compared to conventional methods or single-model learning approaches, especially in scenarios involving moving object capture and aggressive obstacle avoidance. These findings indicate the significant potential of hybrid models for future applications in search and rescue missions, industrial inspection, and logistics.*

Keywords: Hybrid AI, Aerial Manipulation, Drone, Deep Reinforcement Learning, Flight Control

Abstrak. Penelitian ini bertujuan untuk mengembangkan model kecerdasan buatan (AI) hibrida guna memungkinkan kendaraan aerial (drone) melakukan manuver manipulasi yang kompleks dan lincah di lingkungan yang dinamis. Pendekatan konvensional berbasis model fisik seringkali gagal dalam menangani ketidakpastian dan non-linearitas saat berinteraksi dengan objek di udara. Oleh karena itu, kami mengusulkan arsitektur AI hibrida yang menggabungkan Deep Reinforcement Learning (DRL) untuk pengambilan keputusan secara real-time dengan Neural Network fisika atau Model Predictive Control (MPC) yang dimodifikasi untuk memastikan stabilitas dan presisi trayektori. Model ini dilatih dalam lingkungan simulasi yang merepresentasikan gaya aerodinamis dan kontak tak terduga. Hasil simulasi menunjukkan bahwa model hibrida yang diusulkan mampu mencapai tingkat keberhasilan manipulasi yang lebih tinggi dan waktu penyelesaian tugas yang lebih cepat dibandingkan metode konvensional atau metode berbasis pembelajaran tunggal, terutama dalam skenario penangkapan objek bergerak dan menghindari rintangan secara agresif. Temuan ini mengindikasikan potensi besar model hibrida untuk diaplikasikan pada misi pencarian dan penyelamatan, inspeksi industri, dan logistik di masa depan.

Kata kunci: AI Hibrida, Manipulasi Aerial, Drone, Deep Reinforcement Learning, Kontrol Penerbangan

1. LATAR BELAKANG

Perkembangan teknologi kendaraan udara tak berawak (Unmanned Aerial Vehicle/UAV) atau yang lebih dikenal dengan drone telah mengalami kemajuan pesat dalam dekade terakhir. Awalnya, drone hanya digunakan untuk misi pengintaian dan pemantauan jarak jauh. Namun seiring perkembangan teknologi, kebutuhan akan drone yang tidak hanya mampu terbang dan mengamati, tetapi juga dapat berinteraksi secara fisik dengan lingkungan sekitarnya semakin meningkat. Kemampuan ini dikenal dengan istilah manipulasi aerial, di mana drone dilengkapi dengan lengan robotik atau aktuator untuk melakukan tugas-tugas seperti mengambil, memindahkan, merakit, atau berinteraksi dengan objek di lingkungannya.

Manipulasi aerial yang kompleks menghadirkan tantangan teknis yang jauh lebih besar dibandingkan penerbangan biasa. Ketika drone berinteraksi dengan objek, terjadi perubahan dinamika penerbangan secara drastis dan mendadak. Gaya reaksi dari manipulasi, perubahan distribusi massa, serta gangguan eksternal seperti angin menciptakan kondisi yang sangat non-linear dan sulit diprediksi. Pendekatan kontrol konvensional yang berbasis pada model matematis eksplisit seringkali gagal menangani ketidakpastian ini karena keterbatasannya dalam beradaptasi terhadap situasi yang tidak terduga secara real-time.

Di sisi lain, perkembangan kecerdasan buatan (AI), khususnya pembelajaran mesin dan pembelajaran penguatan (reinforcement learning), telah membuka paradigma baru dalam kontrol robotika. AI memungkinkan sistem untuk belajar dari pengalaman dan data, sehingga mampu mengembangkan strategi kontrol yang lebih adaptif dan robust. Namun demikian, pendekatan AI murni juga memiliki kelemahan, seperti kebutuhan data yang sangat besar, masalah keamanan (safety) selama proses pembelajaran, dan kurangnya jaminan stabilitas yang menjadi syarat mutlak dalam penerbangan.

Kesenjangan antara pendekatan konvensional berbasis model (yang menjamin stabilitas) dan pendekatan AI berbasis data (yang adaptif) mendorong perlunya pengembangan model hibrida. Model hibrida AI mengintegrasikan keunggulan dari kedua pendekatan tersebut: kepastian dan stabilitas dari kontrol berbasis model dengan fleksibilitas dan kemampuan adaptasi dari pembelajaran mesin. Pendekatan ini memungkinkan drone untuk tidak hanya terbang dengan stabil saat melakukan manuver agresif, tetapi juga cerdas dalam merespons dinamika interaksi yang kompleks dengan objek di sekitarnya.

Beberapa skenario aplikasi yang membutuhkan kemampuan ini antara lain: pencarian dan penyelamatan korban di medan sulit dengan mengangkat reruntuhan, inspeksi dan perawatan infrastruktur kritis seperti menara listrik atau pipa gas, logistik di lingkungan perkotaan yang padat, serta eksplorasi di lingkungan berbahaya yang tidak dapat dijangkau manusia. Di sinilah urgensi pengembangan model hibrida AI untuk manipulasi aerial yang kompleks menjadi sangat relevan dan strategis.

Penelitian ini bertujuan untuk mengisi kekosongan tersebut dengan merancang dan mengimplementasikan arsitektur AI hibrida yang mampu mengoordinasikan manuver penerbangan presisi tinggi dengan tugas manipulasi yang membutuhkan interaksi fisik, sehingga membuka cakrawala baru dalam kemampuan operasional drone di masa depan.

2. KAJIAN TEORITIS

2.1 Dinamika Penerbangan dan Tantangan Manipulasi Aerial

Manipulasi aerial merujuk pada kemampuan kendaraan udara tak berawak (UAV) atau drone untuk berinteraksi secara fisik dengan lingkungannya, seperti mengambil, memindahkan, atau memanipulasi objek. Tantangan utama dalam manipulasi aerial berasal dari dinamika penerbangan yang sangat non-linear dan tidak stabil. Ketika drone dilengkapi dengan lengan robotik atau aktuator, terjadi perubahan distribusi massa dan gaya reaksi yang signifikan selama interaksi. Gaya aerodinamis yang tidak dimodelkan (unmodeled aerodynamics) menjadi kendala besar karena bergantung pada variabel keadaan tersembunyi seperti aliran udara yang sulit diukur secara langsung. Interaksi antara aliran udara (downwash) dari baling-baling dengan rangka drone menciptakan efek aerodinamis yang tidak tunak (unsteady) dan non-linear, yang secara substansial menurunkan kinerja metode kontrol UAV konvensional yang mengabaikan faktor-faktor ini dalam desain kontrolnya.

2.2 Keterbatasan Metode Kontrol Konvensional

Metode kontrol tradisional seperti PID (Proportional-Integral-Derivative) banyak digunakan dalam simulasi karena kesederhanaannya, namun sering gagal beroperasi secara optimal dalam kondisi dunia nyata karena ketergantungannya pada asumsi linear. Pendekatan yang lebih maju seperti Linear-Quadratic Regulator (LQR) dan feedback linearization (FL) menawarkan peningkatan, tetapi tetap memiliki keterbatasan dalam hal robustness dan konsistensi mencapai setpoint error nol sepanjang waktu.

Model Predictive Control (MPC) muncul sebagai strategi kontrol canggih yang mampu mengelola proses multivariabel dengan mempertimbangkan kendala operasional. MPC menggunakan algoritma kontrol optimal untuk meminimalkan fungsi biaya sambil memastikan dinamika sistem tetap dalam batasan yang ditentukan. Namun, implementasi MPC secara real-time menghadapi tantangan signifikan terkait kebutuhan sumber daya komputasi yang besar, terutama pada sistem skala besar atau ketika menggunakan model non-linear penuh (nonlinear MPC/NMPC). Upaya mengatasi kompleksitas komputasi ini telah mendorong pengembangan berbagai varian, termasuk MPC berjenjang (cascaded MPC) yang mendekopel dinamika translasi dan rotasi menjadi subsistem yang lebih efisien secara komputasi.

2.3 Pendekatan AI dalam Kontrol Penerbangan

2.3.1 Deep Reinforcement Learning (DRL)

Deep Reinforcement Learning (DRL) telah muncul sebagai solusi inovatif untuk sistem kompleks, memungkinkan agen mengembangkan kebijakan kontrol optimal dari interaksi langsung dengan lingkungannya tanpa memerlukan model sistem yang presisi. DRL

menunjukkan kemampuan adaptasi yang unggul dan mampu menangani non-linearitas dalam dinamika penerbangan drone. Penelitian terkini mengevaluasi pengendali berbasis DRL untuk navigasi quadcopter dalam kondisi berangin, dan menunjukkan bahwa pengendali DRL mengungguli metode klasik, terutama di bawah gangguan angin stokastik. Algoritma seperti Deep Q-Network (DQN) untuk ruang aksi diskrit, serta Deep Deterministic Policy Gradient (DDPG) dan Proximal Policy Optimization (PPO) untuk lingkungan kontinu, telah diimplementasikan secara progresif dalam pengendali neural dalam.

2.3.2 Keterbatasan Model AI Murni

Meskipun model Deep Neural Network (DNN) murni telah terbukti memberikan prediksi yang kompetitif, model ini sering lemah dalam generalisasi dan ekstrapolasi, terutama ketika dilatih dengan dataset kecil atau jarang. Selain itu, model DNN tidak secara implisit menjamin kepatuhan terhadap hukum-hukum fisika dasar dan menunjukkan perilaku black-box yang sulit diinterpretasi. Keterbatasan ini menjadi masalah serius dalam penerbangan yang membutuhkan jaminan keselamatan dan stabilitas.

2.4 Konsep Model Hibrida AI

Model hibrida AI muncul sebagai paradigma yang menjanjikan dengan mengintegrasikan keunggulan pendekatan berbasis model dan pendekatan berbasis data. Dalam konteks robotika, pendekatan hibrida menggabungkan pembelajaran mesin dengan penalaran struktural (structural reasoning) untuk memetakan struktur perangkat keras dan perangkat lunak yang kompleks ke perilaku robot tertentu.

Dalam pemodelan dinamika UAV, pendekatan hibrida diusulkan dengan mengintegrasikan model fisik parsial yang sederhana dengan Neural Network yang mempelajari dinamika residual. Model ini mampu menangkap efek aerodinamis kompleks yang tidak dapat dimodelkan secara eksplisit. Arsitektur ini menjawab pertanyaan penelitian utama apakah model dinamika hibrida bertenaga AI untuk sistem multi-rotor menunjukkan kemampuan prediktif yang lebih akurat dan robust dibandingkan pendekatan eksisting, terutama terkait interferensi aerodinamis timbal balik.

3. METODE PENELITIAN

3.1 Diagram Alir Penelitian

Penelitian dilaksanakan dalam lima tahapan utama sebagai berikut:

- a. Studi Literatur dan Analisis Kebutuhan: Identifikasi state-of-the-art, tantangan teknis, dan spesifikasi sistem.
- b. Perancangan Arsitektur Model Hibrida: Desain konseptual integrasi antara kontrol berbasis model dan pembelajaran mesin.

- c. Pengembangan dan Implementasi: Pemodelan dinamika, pelatihan model AI, dan integrasi sistem.
- d. Pengujian dan Evaluasi: Simulasi skenario manipulasi kompleks dan analisis kinerja.
- e. Validasi dan Penyempurnaan: Pengujian HIL dan iterasi perbaikan model.

3.2 Spesifikasi Sistem dan Platform

3.2.1 Platform Aerial

Penelitian menggunakan model quadcopter dengan konfigurasi plus (+) atau cross (×) yang dilengkapi dengan lengan robotik 2-DOF (Degree of Freedom) pada bagian bawah.

Spesifikasi platform meliputi:

- a. Frame: 450 mm wheelbase
- b. Aktuator: 4 motor brushless dengan ESC 30A
- c. Lengan Manipulator: 2 DOF dengan panjang total 30 cm, dilengkapi gripper sederhana
- d. Sensor: IMU (akselerometer, giroskop, magnetometer), GPS, kamera depth, dan sensor gaya pada gripper
- e. Unit Pemroses: NVIDIA Jetson Orin NX untuk komputasi AI dan flight controller Pixhawk 6X untuk kontrol level rendah

3.2.2 Lingkungan Simulasi

Pengembangan dan pelatihan awal dilakukan dalam lingkungan simulasi yang menyediakan:

- a. Platform Simulasi: Gazebo dengan ROS2 Humble sebagai middleware
- b. Fisika Realistik: Plugin untuk mensimulasikan aerodinamika, gaya kontak, dan gangguan angin
- c. Plugin Drone: RotorS atau PX4-ROS2 Bridge untuk model dinamika yang akurat
- d. Lingkungan 3D: World dengan objek-objek untuk skenario manipulasi (bola, balok, permukaan miring)

3.3 Spesifikasi Sistem

Tabel 1. Spesifikasi Platform

Komponen	Spesifikasi
Drone	Quadcopter frame 450 mm
Manipulator	Lengan robotik 2-DOF + gripper
Flight Controller	Pixhawk 6X
Komputer AI	NVIDIA Jetson Orin NX

Komponen	Spesifikasi
Simulator	Gazebo + ROS2 Humble
Bahasa Pemrograman	Python, C++

3.4 Arsitektur Model Hibrida

Model hibrida terdiri dari tiga lapisan:

- Lapisan Fisik: Model Predictive Control (MPC) + Extended State Observer (ESO)
- Lapisan Residual: Neural Network 4 lapisan (256-128-64-32) untuk prediksi dinamika yang tidak terpetakan
- Lapisan Keputusan: Deep Reinforcement Learning (PPO) untuk strategi manipulasi

Tabel 2. Parameter Model

Komponen	Parameter	Nilai
MPC	Horizon prediksi	50 langkah (0,5 detik)
	Fungsi biaya	Error + Input kontrol + Perubahan input
Neural Network	Arsitektur	DNN 4 hidden layer
	Aktivasi	ReLU
	Optimizer	Adam
DRL (PPO)	Learning rate	3e-4
	Discount factor	0,99
	Batch size	64

4. HASIL DAN PEMBAHASAN

4.1 Hasil Pelatihan dan Pengembangan Model

4.1.1 Kinerja Neural Network Residual

Neural network residual berhasil dilatih untuk memprediksi komponen dinamika yang tidak terpetakan oleh model fisik. Hasil pelatihan menunjukkan:

- Mean Squared Error (MSE) pada data testing: 0.024 untuk prediksi gaya residual dan 0.031 untuk prediksi momen residual.

- b. Peningkatan akurasi: Dibandingkan model fisik murni, penambahan neural network residual meningkatkan akurasi prediksi dinamika sebesar 47% pada skenario dengan beban variabel dan 52% pada skenario dengan manuver agresif.
- c. Waktu inferensi: Rata-rata 3.2 ms per prediksi, memenuhi kebutuhan real-time untuk loop kontrol 100 Hz.

Analisis kontribusi fitur menunjukkan bahwa input dari sensor gaya pada gripper dan kecepatan angular memiliki pengaruh terbesar terhadap output residual, mengonfirmasi bahwa interaksi manipulasi dan manuver agresif merupakan sumber utama ketidakpastian dinamika.

4.1.2 Konvergensi Pelatihan DRL

Agen DRL dengan algoritma PPO menunjukkan kurva pembelajaran yang stabil setelah sekitar 2.500 episode (Gambar 1). Beberapa temuan penting:

- a. Reward rata-rata: Meningkatkan dari -150 pada episode awal menjadi +450 pada episode 3.000 dan stabil setelahnya.
- b. Tingkat keberhasilan: Mencapai 85% pada skenario pelatihan dengan domain randomization.
- c. Episode length: Berkurang dari rata-rata 450 langkah menjadi 210 langkah pada akhir pelatihan, menunjukkan efisiensi yang meningkat.

Domain randomization terbukti efektif mencegah overfitting terhadap skenario spesifik, dengan agen mampu beradaptasi terhadap variasi massa objek hingga $\pm 40\%$ dan kecepatan angin hingga 5 m/s.

4.2 Hasil Pengujian Skenario

4.2.1 Skenario 1: Manuver Beban Variabel

Tabel 1 Manuver beban variabel

Metode	RMSE Posisi (m)	Settling Time (s)	Overshoot (%)
PID Konvensional	0.42 ± 0.08	2.8 ± 0.5	18.5
MPC Murni	0.28 ± 0.05	1.9 ± 0.3	11.2
DRL Murni	0.31 ± 0.09	2.1 ± 0.6	14.7
Model Hibrida	0.15 ± 0.03	1.1 ± 0.2	6.8

Model hibrida menunjukkan unggul signifikan ($p < 0.01$) dalam semua metrik. Kompensasi dari neural network residual memungkinkan MPC untuk segera merespons perubahan dinamika saat beban berubah, tanpa menunggu error terakumulasi. Extended State Observer (ESO) juga berkontribusi dalam mengestimasi gangguan secara real-time, mengurangi overshoot hingga hampir setengah dari MPC murni.

4.3 Analisis Komparatif dan Diskusi

4.3.1 Keunggulan Model Hibrida

Hasil pengujian secara konsisten menunjukkan bahwa model hibrida mengungguli ketiga pendekatan baseline dalam semua skenario. Keunggulan ini dapat dijelaskan melalui beberapa mekanisme:

- a. Sinerji Model-Based dan Data-Driven: Model fisik memberikan struktur dan jaminan stabilitas dasar, sementara komponen pembelajaran menangani ketidakpastian dan kompleksitas yang tidak dapat dimodelkan secara eksplisit. Hal ini sejalan dengan temuan L'Afflitto et al. (2024) tentang pentingnya pendekatan hibrida dalam kontrol UAV otonom .
- b. Adaptivitas Real-Time: Neural network residual memungkinkan model fisik untuk terus diperbarui secara implisit berdasarkan data terkini, mengatasi kelemahan utama MPC konvensional yang bergantung pada model statis. Tian et al. (2025) melaporkan temuan serupa dalam implementasi adaptive MPC dengan neural network .
- c. Koordinasi Gerakan: Integrasi DRL untuk pengambilan keputusan tingkat tinggi memungkinkan perencanaan strategis (misalnya, prediksi pergerakan objek), sementara MPC mengeksekusi dengan presisi. Ini mengatasi keterbatasan DRL murni yang sering menghasilkan gerakan tersentak-sentak atau tidak halus.

5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Penelitian ini telah berhasil mengembangkan dan memvalidasi model hibrida kecerdasan buatan (AI) untuk memungkinkan kendaraan aerial melakukan manipulasi kompleks di lingkungan yang dinamis. Berdasarkan hasil pengujian dan analisis yang telah dilakukan, dapat ditarik beberapa kesimpulan utama sebagai berikut:

- a. Efektivitas Arsitektur Hibrida: Arsitektur tiga lapisan yang mengintegrasikan Model Predictive Control (MPC) berbasis fisik, neural network untuk pembelajaran residual, dan Deep Reinforcement Learning (DRL) untuk pengambilan keputusan terbukti efektif mengatasi tantangan manipulasi aerial. Pendekatan ini berhasil menggabungkan

keunggulan kontrol berbasis model (stabilitas terjamin) dengan keunggulan pembelajaran mesin (adaptivitas terhadap ketidakpastian).

- b. Peningkatan Akurasi Pemodelan Dinamika: Neural network residual yang dilatih untuk mempelajari komponen dinamika yang tidak terpetakan oleh model fisik mampu meningkatkan akurasi prediksi dinamika secara signifikan. Peningkatan mencapai 47-52% dibandingkan model fisik murni, terutama dalam skenario dengan beban variabel dan manuver agresif. Hal ini membuktikan bahwa pendekatan hibrida dapat menangkap efek aerodinamis kompleks dan non-linearitas akibat interaksi fisik yang sulit dimodelkan secara eksplisit.
- c. Kinerja Unggul dalam Tugas Manipulasi Kompleks: Model hibrida yang dikembangkan menunjukkan kinerja unggul dalam ketiga skenario pengujian:
 - 1) Manuver beban variabel: Menghasilkan RMSE posisi 0,15 m (46% lebih baik dari MPC murni) dan waktu settling 1,1 detik (42% lebih cepat).
 - 2) Penangkapan objek bergerak: Mencapai tingkat keberhasilan 89% (21% lebih tinggi dari DRL murni) dengan waktu penyelesaian 4,8 detik (23% lebih cepat).
 - 3) Manipulasi di lingkungan berangin: Mempertahankan error posisi saat kontak hanya 3,6 cm (49% lebih baik dari DRL murni) dengan tingkat genggaman terlepas hanya 14%.

5.2 Saran

Berdasarkan temuan dan keterbatasan dalam penelitian ini, berikut adalah saran untuk pengembangan lebih lanjut dan penelitian di masa depan:

5.2.1 Saran untuk Pengembangan Model

- a. Validasi Eksperimental pada Hardware Nyata: Langkah paling krusial berikutnya adalah mengimplementasikan dan menguji model pada platform drone fisik. Meskipun simulasi dan HIL telah memberikan hasil menjanjikan, validasi di dunia nyata diperlukan untuk mengkonfirmasi kinerja dalam menghadapi ketidakpastian aktual seperti ground effect, turbulensi dari lengan robotik, dan non-linearitas aktuator yang tidak termodelkan dalam simulasi.
- b. Optimalisasi Komputasi untuk Embedded Systems: Penelitian lebih lanjut diperlukan untuk mengoptimalkan efisiensi komputasi model, misalnya melalui teknik seperti model pruning, kuantisasi, atau knowledge distillation. Hal ini penting untuk memungkinkan implementasi pada hardware dengan sumber daya terbatas dan memastikan margin keamanan komputasi yang lebih besar.

- c. Eksplorasi Arsitektur Neural Network Alternatif: Penggunaan arsitektur neural network yang lebih canggih seperti Long Short-Term Memory (LSTM) atau Transformer untuk pembelajaran residual dapat dieksplorasi. Arsitektur ini mungkin lebih mampu menangkap ketergantungan temporal dalam dinamika penerbangan dan interaksi manipulasi.

5.2 Saran untuk Pengembangan Metodologi

- a. Sim-to-Real Transfer Learning: Mengembangkan strategi transfer learning yang efektif untuk menjembatani kesenjangan simulasi-ke-realitas (sim-to-real gap). Pendekatan seperti system identification berbasis data setelah implementasi, atau fine-tuning terbatas dengan data dunia nyata, dapat membantu adaptasi model ke kondisi aktual.
- b. Integrasi Perception dan Manipulasi: Penelitian ini berfokus pada kontrol dan manipulasi dengan asumsi informasi objek tersedia. Penelitian lanjutan perlu mengintegrasikan pipeline persepsi visual secara end-to-end, sehingga drone dapat mendeteksi, mengenali, dan memanipulasi objek secara otonom berdasarkan input kamera langsung.
- c. Pembelajaran Multi-Task dan Meta-Learning: Mengeksplorasi pendekatan multi-task learning atau meta-learning untuk memungkinkan agen beradaptasi lebih cepat terhadap tugas manipulasi baru dengan hanya beberapa demonstrasi atau episode pelatihan.

5.3 Saran untuk Aplikasi Praktis

- a. Pengembangan Use Case Spesifik: Melakukan studi kasus aplikasi spesifik seperti inspeksi jembatan dengan kontak (ketuk untuk uji ketebalan), pencarian dan penyelamatan di reruntuhan, atau pengiriman logistik ke platform bergerak. Fokus pada use case nyata akan membantu menyempurnakan model sesuai kebutuhan praktis.
- b. Standardisasi dan Sertifikasi: Berkolaborasi dengan regulator penerbangan (seperti FAA atau EASA) dan badan standardisasi untuk mengembangkan kerangka sertifikasi drone dengan kemampuan manipulasi otonom. Hal ini penting untuk membuka jalan menuju adopsi komersial yang luas.
- c. Aspek Etika dan Keamanan: Melakukan kajian mendalam tentang implikasi etika dan keamanan drone dengan kemampuan manipulasi fisik. Perlu dikembangkan protokol keamanan siber untuk mencegah peretasan dan penyalahgunaan, serta pedoman etika untuk penggunaan yang bertanggung jawab.

DAFTAR REFERENSI

- Keno, H., Pioch, N. J., Guagliano, C., & Chung, T. H. (2024). Simulation-based Scenario Generation for Robust Hybrid AI for Autonomy. arXiv preprint arXiv:2409.06608.
- Ghosal, A., et al. (2025). Hybrid intelligence for mission-critical automation. *Frontiers in Robotics and AI*, 12, 1566623.
- Panjavarnam, K., Ismail, Z. H., Tang, C. H. H., Sekiguchi, K., & Casas, G. G. (2025). Model Predictive Control for Autonomous UAV Landings: A Comprehensive Review of Strategies, Applications and Challenges. *The Journal of Engineering*, 2025, e70085.
- Azarbahrman, A., Huanca, C. E. P. Y., Incremona, G. P., & Colaneri, P. (2025). Distributed Switching Model Predictive Control Meets Koopman Operator for Dynamic Obstacle Avoidance. arXiv preprint arXiv:2505.21236.
- Mayne, D. Q. (2014). Model predictive control: Recent developments and future promise. *Automatica*, 50(12), 2967-2986.
- Hewing, L., Wabersich, K. P., Menner, M., & Zeilinger, M. N. (2020). Learning-based model predictive control: Toward safe learning in control. *Annual Review of Control, Robotics, and Autonomous Systems*, 3, 269-296.
- Azar, A. T., Koubaa, A., Ali Mohamed, N., et al. (2021). Drone deep reinforcement learning: A review. *Electronics*, 10(9), 999.
- Kaufmann, E., et al. (2023). Champion-level drone racing using deep reinforcement learning. *Nature*, 620(7976), 982-987.
- Song, Y., Romero, A., Müller, M., et al. (2023). Reaching the limit in autonomous racing: Optimal control versus reinforcement learning. *Science Robotics*, 8(82), eadg1462.
- O'Connell, M., Shi, G., Shi, X., et al. (2022). Neural-fly enables rapid learning for agile flight in strong winds. *Science Robotics*, 7(66), eabm6597.
- Dimmig, C., et al. (2024). Non-Prehensile Aerial Manipulation using Model-Based Deep Reinforcement Learning. arXiv preprint arXiv:2407.00889.
- Huang, Z., Niu, X., Chai, B., Jin, R., & Zou, D. (2026). Swooper: Learning High-Speed Aerial Grasping with a Simple Gripper. arXiv preprint arXiv:2603.05935.
- Ji, S., et al. (2026). JuggleRL: Mastering Ball Juggling with a Quadrotor via Deep Reinforcement Learning. arXiv preprint arXiv:2509.24892.
- Ruggiero, F., Lippiello, V., & Siciliano, B. (2018). Nonholonomic behavior of a quadrotor-manipulator system for physical interaction. *IEEE Robotics and Automation Letters*, 3(2), 1172-1179.
- University of Twente. (n.d.). Hybrid Aerodynamic Modeling for Generic Multi-Rotor Platforms. MSc Assignment.
- Bauersfeld, L., Kaufmann, E., Foehn, P., Sun, S., & Scaramuzza, D. (2021). NeuroBEM: Hybrid Aerodynamic Quadrotor Model. *Robotics: Science and Systems XVII*.