

PENGEMBANGAN SISTEM *CLOSED-LOOP AUTONOMOUS NAVIGATION* PADA KECOA CYBORG BERBASIS PERBANDINGAN MODEL *MARKERLESS POSE ESTIMATION* DAN KOMUNIKASI NIRKABEL ESP-NOW

*Hafiz Akbar Simanjanrang¹, Mochammad Ariyanto², Munadi²

¹Mahasiswa Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro

²Dosen Jurusan Teknik Mesin, Fakultas Teknik, Universitas Diponegoro
Jl. Prof. Sudharto, SH., Tembalang-Semarang 50275, Telp. +62247460059

*E-mail: hafizakbar@students.undip.ac.id

Abstrak

Penelitian ini mengembangkan sistem navigasi otonom closed-loop pada Madagascar hissing cockroach (*Gromphadorhina portentosa*) cyborg menggunakan pendekatan markerless pose estimation berbasis deep learning sebagai alternatif terhadap metode marker-based dan external motion capture system yang umum digunakan pada penelitian cyborg insect sebelumnya. Tiga model pose estimation, yaitu YOLO Pose v8, Heatmap Hourglass Network, dan DeepLabCut (DLC), dilatih dan dibandingkan untuk menentukan sudut hadap (heading angle) kecoa secara real-time melalui kamera tunggal topview. Estimasi sudut tersebut digunakan sebagai umpan balik dalam algoritma navigasi closed-loop yang mengarahkan kecoa menuju serangkaian titik checkpoint melalui stimulasi elektromekanis pada antena dan cerci, yang ditransmisikan secara nirkabel melalui protokol ESP-NOW ke backpack berbasis ESP32-C6 yang terpasang pada tubuh kecoa. Evaluasi dilakukan berdasarkan empat metrik, yaitu akurasi estimasi sudut (MAE, RMSE, R^2), kompleksitas dan latensi inferensi, frame rate (FPS), serta tingkat noise estimasi sudut. Hasil pengujian menunjukkan bahwa model YOLO Pose v8 memberikan performa terbaik dengan MAE 2,75°, RMSE 3,70°, dan R^2 0,9988, didukung oleh arsitektur ringkas (3,08 juta parameter) dan latensi inferensi rendah (32 ms), sehingga ditetapkan sebagai model terbaik untuk diintegrasikan ke dalam sistem navigasi. Pengujian sistem navigasi otonom pada tiga skenario lintasan (zigzag, belok kanan, dan belok kiri) menunjukkan bahwa kecoa cyborg berhasil mencapai target checkpoint pada seluruh percobaan dengan FPS rata-rata di atas 20, mengonfirmasi kelayakan sistem markerless untuk aplikasi navigasi biohybrid secara real-time tanpa penanda fisik maupun perangkat motion capture eksternal.

Kata kunci: *cyborg insect; deep learning; markerless pose estimation; navigasi closed-loop; yolo pose*

Abstract

This study develops a closed-loop autonomous navigation system for a Madagascar hissing cockroach (Gromphadorhina portentosa) cyborg using a deep-learning-based markerless pose estimation approach as an alternative to the marker-based and external motion-capture methods commonly used in prior cyborg insect research. Three pose estimation models, namely YOLO Pose v8, Heatmap Hourglass Network, and DeepLabCut (DLC), were trained and compared to determine the cockroach heading angle in real time using a single top-view camera. The estimated angle serves as feedback in a closed-loop navigation algorithm that guides the cockroach through a series of checkpoints via electromechanical stimulation of the antennae and cerci, wirelessly transmitted through the ESP-NOW protocol to an ESP32-C6-based backpack mounted on the insect's body. Evaluation was conducted using four metrics: angle estimation accuracy (MAE, RMSE, R^2), model complexity and inference latency, frame rate (FPS), and angle estimation noise. Results show that YOLO Pose v8 achieved the best performance with an MAE of 2.75°, RMSE of 3.70°, and R^2 of 0.9988, supported by a compact architecture (3.08 million parameters) and low inference latency (32 ms), establishing it as the best model for integration into the navigation system. Autonomous navigation tests on three trajectory scenarios (zigzag, right-turn, and left-turn) showed that the cyborg cockroach successfully reached the target checkpoints in all trials with an average FPS above 20, confirming the feasibility of the markerless system for real-time biohybrid navigation applications without physical markers or external motion-capture devices.

Keywords: *closed-loop navigation; cyborg insect; deep learning; markerless pose estimation; yolo pose*

1. Pendahuluan

Penggabungan sistem biologis dengan komponen elektronik telah membuka arah baru dalam pengembangan bio-hybrid robotics, di mana organisme hidup dimanfaatkan sebagai basis kendali dan aktuasi alami. Cyborg insects menjadi salah satu platform paling menjanjikan dalam bidang ini karena memadukan efisiensi energi biologis dengan kemampuan kendali eksternal yang presisi. Madagascar hissing cockroach (*Gromphadorhina portentosa*) dipilih sebagai objek penelitian karena memiliki tubuh yang kokoh, mobilitas tinggi, serta ketahanan terhadap kondisi ekstrem, sehingga ideal untuk eksperimen robotika berskala mikro [9].

Rangsangan listrik berintensitas rendah pada antena terbukti mampu mengubah arah pergerakan serangga, sedangkan getaran pada bagian posterior tubuh memicu gerak maju dan meningkatkan kecepatan locomotion, sehingga arah dan

kecepatan gerak dapat dimodulasi secara eksternal tanpa menghilangkan respons biologis alaminya [8]. Penelitian terdahulu mengembangkan sistem navigasi berbasis umpan balik untuk mengarahkan kecoa cyborg di lingkungan kompleks, namun masih bergantung pada external motion capture system (Vicon) dan marker reflektif untuk memperoleh data posisi dan orientasi secara akurat [6]. Ketergantungan pada perangkat pelacak eksternal ini menimbulkan beberapa keterbatasan, di antaranya kebutuhan kalibrasi lingkungan yang kompleks, biaya perangkat yang tinggi, serta portabilitas yang rendah.

Pendekatan berbasis penanda fisik (marker-based) juga masih dominan digunakan pada berbagai penelitian cyborg insect, misalnya penanda berbentuk huruf 'Y' yang dipasang pada punggung kecoa sebagai titik referensi sistem motion capture dalam navigasi kawanan [2]. Meskipun efektif, pendekatan ini memiliki kelemahan signifikan karena penanda fisik rentan tersangkut pada rintangan dan dapat mengubah perilaku alami serangga. Markerless pose estimation berbasis deep learning menawarkan solusi atas keterbatasan tersebut, karena mampu mengenali titik-titik anatomi (keypoints) dari citra video secara otomatis tanpa sensor fisik tambahan. Model berbasis heatmap convolutional networks terbukti mampu memperkirakan posisi dan orientasi tubuh dengan akurasi tinggi bahkan pada kondisi pencahayaan yang bervariasi [7].


Penelitian ini mengusulkan pendekatan terpadu yang menggabungkan markerless pose estimation berbasis deep learning dengan sistem navigasi otonom closed-loop pada kecoa cyborg, secara eksplisit menghilangkan ketergantungan pada marker fisik maupun external motion capture system, dan hanya menggunakan kamera tunggal top-view. Madagascara hissing cockroach dikendalikan melalui kombinasi elektroda mikro pada antena dan motor vibrasi pada cerci, dengan sinyal stimulasi dikirimkan secara nirkabel melalui protokol ESP-NOW dari komputer host ke backpack ESP32-C6 yang terpasang pada tubuh kecoa. Orientasi tubuh kecoa diestimasi secara real-time menggunakan tiga model pose estimation, yaitu YOLO Pose v8, CNN Heatmap, dan DeepLabCut, untuk menentukan sudut hadap (heading angle) yang digunakan sebagai umpan balik dalam sistem kendali navigasi closed-loop, sehingga kecoa dapat diarahkan secara otonom menuju serangkaian titik checkpoint pada tiga skenario lintasan berbeda tanpa intervensi manual.

2. Bahan dan Metode Penelitian

Penelitian ini dilakukan dengan pendekatan eksperimental menggunakan tiga ekor Madagascara hissing cockroach (*Gromphadorhina portentosa*) sebagai platform cyborg insect pada tiga skenario lintasan navigasi, yaitu lintasan zigzag, lintasan dominan belok kanan, dan lintasan dominan belok kiri, masing-masing diulang sebanyak lima kali. Serangga dilengkapi perangkat backpack berisi sistem elektro-mekanis berupa mikroelektroda dan motor getar mini, dan diuji pada lingkungan terkendali dengan pencahayaan dan posisi kamera konstan.

2.1 Bidang Uji dan Konfigurasi Kamera

Bidang uji (testbed) berbentuk persegi dengan dimensi $1,5 \times 1,5$ meter, dikelilingi dinding setinggi 20 cm untuk mencegah serangga keluar area pengamatan tanpa mengganggu pola geraknya. Permukaan bidang uji dibuat dari material datar berwarna kontras untuk memudahkan deteksi keypoint tubuh kecoa dan meminimalkan pantulan cahaya. Kamera ditempatkan tegak lurus di atas bidang uji pada ketinggian 1,8 meter dengan resolusi 1080p dan frame rate 30 FPS, sehingga seluruh area uji tercakup dengan distorsi perspektif minimal. Tampilan top-view area uji eksperimental untuk ketiga skenario lintasan dapat dilihat pada Gambar 1.



Gambar 1. Tampilan top-view area uji eksperimental (a) Lintasan Zigzag (b) Lintasan Belok Kanan (c) Lintasan Belok Kiri

2.2 Perangkat Akuisisi dan Pemrosesan Data

Akuisisi citra menggunakan kamera digital yang terhubung ke laptop melalui kabel USB, diinisialisasi pada resolusi 1280×720 piksel dengan frame rate 30 FPS. Setiap frame mengalami transformasi perspektif (perspective warp) menggunakan homografi 4-titik untuk mengoreksi distorsi kamera, menghasilkan tampilan top-view presisi berukuran 720×720 piksel. Seluruh proses training dan inference dijalankan pada workstation dengan prosesor AMD Ryzen 9 7950X, GPU NVIDIA GeForce RTX 3090 Ti (24 GB VRAM), RAM 64 GB, SSD 2 TB, CUDA versi 11.8, dan Python versi 3.10.18.

2.3 Pelatihan Model Detektor dan Pose Estimation

Model detektor menggunakan arsitektur YOLOv8n dari pustaka Ultralytics untuk menghasilkan bounding box akurat terhadap posisi tubuh kecoa sebagai cropped input bagi ketiga model pose estimation. Parameter pelatihan model detektor disajikan pada Tabel 1.

Tabel 1. Parameter pelatihan model detektor YOLOv8n

Parameter	Nilai
Framework	Ultralytics YOLOv8n
Python Version	3.10.18
CUDA Version	11.8
GPU	NVIDIA GeForce RTX 3090 Ti (24 GB)
Jumlah data training	240 citra
Jumlah data validasi	40 citra
Image size training	720 × 720 px
Batch size	16
Epochs	200
Optimizer	AdamW (lr=0,002; momentum=0,9)
Weight decay	0,0005
Pretrained model	yolov8n.pt
Jumlah kelas	1 (kecoa)
Confidence threshold inferensi	0,2

Tiga model pose estimation dilatih dan dibandingkan menggunakan dataset yang sama sebanyak 300 citra beranotasi (rasio 80:20 untuk training dan validasi) dengan dua keypoint utama, yaitu kepala dan ekor kecoa: YOLO Pose v8 yang mendeteksi keypoint kepala dan ekor secara langsung dalam satu pipeline ringan; Heatmap Hourglass Network yang menggunakan arsitektur encoder-decoder untuk menghasilkan peta probabilitas posisi keypoint (2D Gaussian heatmap); serta DeepLabCut (DLC) versi 3.0.0 yang merupakan kerangka kerja markerless pose estimation berbasis transfer learning (ResNet-50).

2.4 Faktor Komparasi Model

Evaluasi performa dilakukan melalui empat parameter utama: akurasi estimasi sudut terhadap ground truth, kompleksitas model dan inference latency, frame rate (FPS), dan tingkat noise estimasi sudut. Akurasi diukur menggunakan tiga metrik: Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan koefisien determinasi (R^2). Karena data sudut bersifat melingkar, selisih dihitung dengan fungsi normalisasi yang memetakan nilai ke rentang -180° hingga $+180^\circ$.

Inference latency didefinisikan sebagai waktu yang dibutuhkan model pose estimation untuk memproses satu frame ROI hingga menghasilkan koordinat keypoint kepala dan ekor, diukur pada GPU NVIDIA GeForce RTX 3090 Ti dengan CUDA aktif. FPS diukur pada pipeline penuh meliputi akuisisi frame, transformasi perspektif, deteksi YOLO, pemotongan ROI, estimasi pose, pelacakan SORT, perhitungan sudut yaw, hingga rendering visual.

2.5 Estimasi Sudut Orientasi dan Logika Navigasi


Deteksi posisi kecoa menggunakan model YOLO yang menghasilkan bounding box (x_1, y_1, x_2, y_2), yang kemudian diproses oleh algoritma SORT (Simple Online and Realtime Tracking) dengan parameter $\max_age = 80$, $\min_hits = 1$, dan $iou_threshold = 0,05$ untuk mempertahankan identitas kecoa antarframe. Estimasi sudut orientasi (heading angle/yaw) dihitung dari dua keypoint kepala dan ekor menggunakan fungsi $\arctan2$:

$$\psi_k = \arctan2(-\Delta y, \Delta x) \times (180/\pi)$$

Sistem menerapkan kendali bang-bang dengan zona mati (deadzone) sebesar 25° (STIM_THRESHOLD). Apabila jarak Euclidean kecoa terhadap checkpoint aktif kurang dari 75 piksel (CP_RADIUS), stimulasi dimatikan dan target berpindah ke checkpoint berikutnya. Apabila $|\Delta\psi_k| \leq 25^\circ$, kecoa diberi stimulasi cerci untuk bergerak maju lurus; apabila $\Delta\psi_k > 25^\circ$, kecoa diberi stimulasi antena kiri agar berbelok ke kanan; dan apabila $\Delta\psi_k < -25^\circ$, kecoa diberi stimulasi antena kanan agar berbelok ke kiri.


2.6 Instalasi Sistem Stimulasi dan Komunikasi Nirkabel

Elektroda berupa kabel konduktif berdiameter 0,1 mm diinsersi ke dalam rongga antena kecoa, kemudian difiksasi menggunakan clay dan dihubungkan ke pin GPIO pada modul ESP32-C6 receiver. GPIO 19 terhubung ke antena kanan (memicu belok kiri), GPIO 18 ke antena kiri (memicu belok kanan), dan GPIO 3 ke motor vibrasi pada cerci (memicu maju lurus). Backpack berbasis ESP32-C6 dipasang pada bagian dorsal tubuh kecoa, didukung baterai Li-Po 3,7 V/100 mAh. Hasil integrasi sistem backpack pada tubuh kecoa ditunjukkan pada Gambar 2.



Gambar 2. Integrasi elektroda, ESP32-C6, dan motor vibrasi pada kecoa

Sinyal stimulasi yang ditentukan oleh algoritma navigasi diteruskan secara nirkabel menggunakan protokol ESP-NOW pada frekuensi 2,4 GHz [5]. Kode stimulasi dikirim dari komputer host ke ESP32 transmitter melalui komunikasi serial UART (baudrate 9600 bps), kemudian diteruskan ke ESP32 receiver pada tubuh kecoa untuk mengaktifkan sinyal elektrik bifasik pada elektroda. Arsitektur komunikasi closed-loop sistem secara keseluruhan ditunjukkan pada Gambar 3.



Gambar 3. Arsitektur sistem komunikasi closed-loop kecoa biohybrid


2.7 Prosedur Pengujian Navigasi

Pengujian sistem navigasi dilakukan melalui tahapan terstruktur: penentuan jalur navigasi melalui antarmuka CheckpointPicker, verifikasi sistem stimulasi secara manual menggunakan kontrol keyboard, aktivasi tracking dan deteksi real-time, pelaksanaan navigasi otonom, hingga pencatatan output hasil berupa file video, file CSV (memuat waktu, sudut yaw, posisi, FPS, dan kode stimulasi), serta grafik analisis. Pengujian dilaksanakan pada tiga skenario lintasan: zigzag, belok kanan, dan belok kiri, masing-masing sebanyak lima percobaan menggunakan satu ekor kecoa yang berbeda per skenario.

3. Hasil dan Pembahasan

3.1 Hasil Pelatihan Model Detektor

Pelatihan model detektor YOLOv8n dijalankan selama 200 epoch dengan model terbaik diperoleh pada epoch ke-187. Loss training menurun dari 11,43 menjadi 2,88, sementara loss validasi menurun dari 9,19 menjadi 2,83, dengan kedua kurva bergerak hampir berhimpitan, mengindikasikan tidak adanya overfitting yang signifikan. Precision akhir mencapai 0,997 dan recall mencapai 1,000. mAP@0.5 mencapai konvergensi sejak epoch ke-20 dan stabil pada nilai 0,995, sedangkan mAP@0.5:0.95 mencapai nilai terbaik 0,717 pada epoch ke-187. Kurva konvergensi pelatihan ditunjukkan pada Gambar 4.



Gambar 4. Hasil pelatihan model detektor YOLOv8n

3.2 Perbandingan Akurasi Estimasi Sudut

Perbandingan akurasi ketiga model pose estimation berdasarkan tiga metrik evaluasi disajikan pada Tabel 2.

Tabel 2. Perbandingan matriks evaluasi model pose estimation

Model	MAE (°)	RMSE (°)	R ²
YOLO	2,75	3,70	0,9988
Heatmap	3,08	7,28	0,9953
DLC	5,89	7,42	0,9951

Model YOLO mencatatkan MAE dan RMSE terendah serta R^2 tertinggi, menunjukkan akurasi estimasi sudut heading yang paling baik. Model heatmap memperoleh MAE $3,08^\circ$ dan RMSE $7,28^\circ$ dengan $R^2 = 0,9953$, menunjukkan korelasi kuat meskipun akurasinya sedikit lebih rendah dibandingkan YOLO. Model DLC menghasilkan MAE tertinggi ($5,89^\circ$) dan RMSE tertinggi ($7,42^\circ$) dengan $R^2 = 0,9951$, mengindikasikan keterbatasan dalam estimasi sudut yang presisi.


3.3 Kompleksitas Model, Latensi, dan FPS

Model YOLO Pose memiliki arsitektur ringkas dengan 3,08 juta parameter dan latensi inferensi terendah sebesar 31,6 ms per frame ($\sigma = 14,4$ ms). Model heatmap memiliki parameter paling sedikit (1,55 juta) namun mencatatkan latensi tertinggi (70,4 ms) akibat arsitektur encoder-decoder dua tahap. Model DLC dengan parameter terbesar (23,67 juta berbasis ResNet-50) mencapai latensi 33,6 ms ($\sigma = 5,0$ ms) yang sebanding dengan YOLO namun dengan konsistensi lebih baik. Perbandingan latensi inferensi ketiga model disajikan pada Tabel 3.

Tabel 3. Perbandingan kompleksitas model dan inference latency

Model	Inference Latency (ms)	Std. Deviasi (ms)
YOLO	31,6	14,4
Heatmap	70,4	—
DLC	33,6	5,0


Dari sisi frame rate keseluruhan pipeline, YOLO Pose mencapai rata-rata FPS sebesar 24,5 ($\sigma = 5,04$), DLC mencapai FPS tertinggi sebesar 30,9 ($\sigma = 2,85$), sedangkan Heatmap Hourglass menunjukkan FPS terendah sebesar 14,6 ($\sigma = 2,33$). Keunggulan FPS DLC bukan cerminan latensi model yang lebih rendah, melainkan konsekuensi dari perbedaan posisi model dalam arsitektur pipeline. Perbandingan FPS dan latency ketiga model ditunjukkan pada Gambar 5.




Gambar 5. Komparasi FPS dan inference latency ketiga model

3.4 Noise Estimasi Sudut dan Penetapan Model Terbaik

Evaluasi noise dilakukan melalui pengambilan lima sampel frame secara acak dari masing-masing model. Model YOLO menunjukkan nilai Δ yang konsisten rendah pada seluruh sampel ($0,6^\circ$ – $5,0^\circ$). Model Heatmap mencatatkan Δ antara $0,0^\circ$ – $3,4^\circ$ namun terdapat satu outlier signifikan sebesar $32,5^\circ$. Model DLC menunjukkan nilai Δ paling besar dan tidak konsisten ($0,7^\circ$ – $12,7^\circ$). Berdasarkan evaluasi komprehensif terhadap akurasi, latensi, FPS, dan noise sudut, model YOLO ditetapkan sebagai model pose estimation terbaik. Perbandingan prediksi terhadap ground truth dan ringkasan keempat faktor komparasi ditunjukkan pada Gambar 6.



Comprehensive Comparison of Pose Estimation Models:
YOLO vs Heatmap vs DeepLabCut (DLC)




Gambar 6. Perbandingan noise estimasi sudut dan penetapan model terbaik

Hal ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa model berbasis YOLO unggul dalam deteksi objek real-time dan lokalisasi objek kecil berkat arsitektur single-stage dan pipeline ekstraksi fitur yang teroptimasi [3]. Dengan mengintegrasikan deteksi dan estimasi pose dalam satu pipeline yang ringan, sistem yang diusulkan secara konsisten mencapai latensi inferensi rendah sebesar 32 ms dan mampu menangani target hewan yang hanya menempati 0,133% dari area frame input.

3.5 Hasil Live Detection dan Navigasi Otonom

Pengujian navigasi otonom menggunakan model YOLO sebagai model pose estimation terbaik dilakukan pada tiga skenario lintasan: zigzag, belok kanan, dan belok kiri, masing-masing sebanyak lima percobaan.


Pada lintasan zigzag, durasi tempuh berkisar antara 76,0 detik hingga 106,4 detik dengan FPS rata-rata antara 21,4–22,7 FPS. Trajektori gabungan kelima percobaan, perubahan sudut yaw, dan kinerja FPS ditunjukkan pada Gambar 7.




Gambar 7. Trajektori, grafik yaw, dan grafik FPS pada 5 percobaan lintasan zigzag

Kelima percobaan menunjukkan pola lintasan yang relatif konsisten menuju titik tujuan. Variasi yaw rata-rata dari $-44,3^\circ$ (Trial 4) hingga $+71,9^\circ$ (Trial 2), mencerminkan koreksi arah berulang yang memang dibutuhkan pada lintasan jenis ini. Nilai FPS yang stabil di atas 20 pada seluruh trial mengonfirmasi kinerja pipeline yang memadai.

Pada lintasan belok kanan, durasi tempuh antarpercobaan bervariasi antara 74,5 detik hingga 132,3 detik dengan FPS rata-rata antarpercobaan berkisar antara 21,8 hingga 24,3. Trajektori gabungan kelima percobaan, perubahan sudut yaw, dan kinerja FPS ditunjukkan pada Gambar 8.







Gambar 8. Trajektori, grafik yaw, dan grafik FPS pada 5 percobaan lintasan belok kanan

Seluruh percobaan berhasil membentuk kurva belok kanan yang serupa. Nilai yaw rata-rata bervariasi dari $-15,8^\circ$ hingga $7,5^\circ$, mengindikasikan kecenderungan orientasi kecoa sedikit ke arah kiri selama manuver belok kanan berlangsung. FPS yang konsisten di atas 20 pada seluruh percobaan mengonfirmasi stabilitas sistem deteksi.

Pada lintasan belok kiri, durasi tempuh bervariasi dari 79,4 detik (Trial 3) hingga 225,1 detik (Trial 2). Trial 2 yang paling lama mengindikasikan habituasi, yaitu penurunan sensitivitas kecoa terhadap stimulasi berulang, bukan akibat keterbatasan sistem deteksi (FPS tetap stabil 23,0). Trajektori gabungan kelima percobaan, perubahan sudut yaw, dan kinerja FPS ditunjukkan pada Gambar 9.





Gambar 9. Trajektori, grafik yaw, dan grafik FPS pada 5 percobaan lintasan belok kiri

FPS sistem deteksi tetap stabil di atas 20 FPS pada seluruh percobaan, dengan rata-rata berkisar 22,0–24,7 FPS, mengonfirmasi bahwa variasi durasi tempuh murni ditentukan oleh perilaku biologis subjek, bukan keterbatasan komputasi.

4. Kesimpulan

Penelitian ini berhasil mengembangkan dan mengevaluasi sistem navigasi otonom closed-loop pada Madagascar hissing cockroach (*Gromphadorhina portentosa*) cyborg berbasis markerless pose estimation menggunakan kamera tunggal top-view, sebagai alternatif terhadap metode marker-based dan external motion capture system yang digunakan pada penelitian-penelitian sebelumnya. Pendekatan yang diusulkan secara eksplisit menghilangkan ketergantungan pada penanda fisik maupun perangkat pelacak eksternal seperti sistem Vicon, sehingga meningkatkan portabilitas dan menurunkan biaya implementasi tanpa mengorbankan keandalan sistem navigasi.

Dari perbandingan tiga model pose estimation, YOLO Pose v8 terbukti memberikan performa terbaik secara keseluruhan. Model ini mencatatkan akurasi estimasi sudut tertinggi dengan MAE 2,75°, RMSE 3,70°, dan R^2 0,9988, didukung arsitektur yang paling ringkas (3,08 juta parameter), latensi inferensi rendah (31,6 ms, $\sigma = 14,4$ ms), serta tingkat noise sudut yang paling konsisten ($\Delta = 0,6^\circ$ – $5,0^\circ$) dibandingkan model Heatmap Hourglass Network dan DeepLabCut. Model Heatmap Hourglass Network, meskipun memiliki jumlah parameter terkecil (1,55 juta), mencatatkan latensi tertinggi (70,4 ms) akibat bottleneck pada arsitektur encoder-decoder dua tahap, serta terdapat satu outlier noise yang signifikan ($\Delta = 32,5^\circ$) yang mengindikasikan ketidakstabilan pada kondisi tertentu. Model DeepLabCut berbasis ResNet-50 (23,67 juta parameter) menghasilkan MAE tertinggi (5,89°) dan tingkat noise yang paling tidak konsisten ($\Delta = 0,7^\circ$ – $12,7^\circ$), meskipun latensi inferensinya (33,6 ms) sebanding dengan YOLO.

Pelatihan model detektor YOLOv8n menghasilkan konvergensi yang stabil dengan precision 0,997, recall 1,000, dan mAP@0.5 sebesar 0,995 pada epoch ke-187 dari total 200 epoch pelatihan, tanpa indikasi overfitting yang signifikan. Hal ini mengonfirmasi bahwa arsitektur YOLOv8n mampu mendeteksi tubuh kecoa secara konsisten meskipun objek target hanya menempati sekitar 0,133% dari total area frame input, yang merupakan tantangan utama dalam deteksi objek berskala sangat kecil pada resolusi 720×720 piksel.

Sistem navigasi closed-loop yang mengintegrasikan estimasi sudut YOLO Pose v8 dengan komunikasi nirkabel ESP-NOW berhasil mengarahkan kecoa cyborg menuju checkpoint yang ditentukan pada ketiga skenario lintasan pengujian. Pada lintasan zigzag, seluruh percobaan berhasil diselesaikan dalam durasi 76,0–106,4 detik dengan FPS rata-rata 21,4–22,7. Pada lintasan belok kanan, durasi tempuh berkisar antara 74,5–132,3 detik dengan FPS rata-rata 21,8–24,3. Pada lintasan belok kiri, durasi tempuh bervariasi dari 79,4 detik hingga 225,1 detik; variasi yang lebih lebar pada lintasan ini disebabkan oleh fenomena habituasi pada Trial 2, yaitu penurunan sensitivitas kecoa terhadap stimulasi berulang dalam durasi pengujian yang panjang, bukan akibat keterbatasan sistem komputasi (FPS Trial 2 tetap stabil di 23,0 FPS).

Kinerja FPS pipeline keseluruhan yang secara konsisten berada di atas 20 FPS pada seluruh skenario dan percobaan mengonfirmasi bahwa sistem mampu mempertahankan kecepatan pemrosesan yang memadai untuk mendukung navigasi otonom secara real-time. Nilai ini melampaui ambang batas minimum yang diperlukan untuk sistem pengendalian biologis

berbasis umpan balik visual, di mana latensi respons stimulasi terhadap perubahan orientasi harus lebih pendek dari waktu reaksi kecoa terhadap rangsangan eksternal. Stabilitas FPS yang diamati juga mengindikasikan bahwa pipeline yang dikembangkan, mencakup akuisisi frame, transformasi perspektif, deteksi YOLO, estimasi pose, pelacakan SORT, dan rendering, dapat berjalan secara efisien pada perangkat keras komersial tanpa memerlukan optimasi tambahan untuk skenario pengujian yang digunakan.

Dibandingkan dengan penelitian cyborg insect sebelumnya yang bergantung pada sistem Vicon motion capture [6] atau penanda fisik berbentuk huruf 'Y' yang memerlukan lingkungan terkalibrasi [2], pendekatan yang diusulkan dalam penelitian ini berhasil mencapai tingkat akurasi orientasi yang sebanding ($MAE < 3^\circ$) menggunakan hanya kamera tunggal berbiaya rendah tanpa penanda apapun pada tubuh kecoa. Penghapusan penanda fisik juga berkontribusi pada preservasi perilaku alami serangga selama pengujian, karena tidak ada beban tambahan yang memengaruhi respons neuromuskular kecoa terhadap stimulasi yang diberikan. Hal ini menjadi keunggulan fundamental dari pendekatan markerless dibandingkan metode konvensional, khususnya untuk aplikasi jangka panjang maupun pengujian di lingkungan non-laboratorium.

Berdasarkan hasil dan keterbatasan yang ditemukan selama penelitian ini, beberapa saran pengembangan dapat diajukan untuk penelitian lanjutan. Pertama, pengujian pada lingkungan yang lebih kompleks dengan rintangan dinamis dan pencahayaan tidak seragam perlu dilakukan untuk menguji robustitas sistem markerless pada kondisi non-ideal. Kedua, integrasi mekanisme deteksi dan adaptasi habituasi pada algoritma kendali, misalnya dengan modulasi amplitudo atau frekuensi stimulasi secara adaptif, dapat meningkatkan konsistensi respons subjek selama pengujian berdurasi panjang. Ketiga, penerapan sistem pada platform multi-kecoa untuk aplikasi swarm robotics menjadi langkah logis berikutnya, mengingat sistem markerless yang dikembangkan tidak memerlukan instalasi penanda individual pada setiap subjek, sehingga lebih skalabel dibandingkan pendekatan marker-based untuk skenario kawanan. Keempat, eksplorasi model pose estimation yang lebih ringan seperti YOLO Pose versi nano atau tiny dapat dilakukan untuk memungkinkan inferensi pada perangkat edge computing yang terpasang onboard, menuju sistem cyborg yang sepenuhnya otonom tanpa ketergantungan pada komputer host eksternal.

5. Daftar Pustaka

- [1] Ariyanto, M., Mohammad, C., & Refat, M. (2024). Feedback control of automatic navigation for cyborg cockroach without external motion capture system. *Heliyon*, 10(5), e26987. <https://doi.org/10.1016/j.heliyon.2024.e26987>
- [2] Bai, Y., Thanh, P., Ngoc, T., Nguyen, H. D., Le, D. L., Ha, Q. H., Kai, K., Xiang, Y., To, S., Deng, Y., Song, J., Wakamiya, N., Sato, H., & Ogura, M. (2025). Swarm navigation of cyborg-insects in unknown obstructed soft terrain. *Nature Communications*, June 2024, 1–5. <https://doi.org/10.1038/s41467-024-55197-8>
- [3] Cervera, E. (2020). GPU-Accelerated Vision for Robots: Improving System Throughput Using OpenCV and CUDA. *IEEE Robotics & Automation Magazine*, 27, 151–158. <https://doi.org/10.1109/MRA.2020.2977601>
- [4] Cole, J., Bozkurt, A., & Lobaton, E. (2020). Localization of biobotic insects using low-cost inertial measurement units. *Sensors (Switzerland)*, 20(16), 1–40. <https://doi.org/10.3390/s20164486>
- [5] Eridani, D. (2021). Comparative Performance Study of ESP-NOW, Wi-Fi, Bluetooth Protocols based on Range, Transmission Speed, Latency, Energy Usage and Barrier Resistance. 2021 International Seminar on Application for Technology of Information and Communication (ISemantic), 322–328. <https://doi.org/10.1109/iSemantic52711.2021.9573246>
- [6] Refat, C. M. M., Ariyanto, M., Tanaka, R., Yamamoto, K., & Morishima, K. (2025). Autonomous Navigation of Bio-Intelligent Cyborg Insect Based on Insect Visual Perception. *Advanced Intelligent Systems*, 7(10). <https://doi.org/10.1002/aisy.202400838>
- [7] Ruescas-Nicolau, A. V., De Rosario, H., Bernabé, E. P., & Juan, M. C. (2024). Positioning errors of anatomical landmarks identified by fixed vertices in homologous meshes. *Gait and Posture*, 108(June 2023), 215–221. <https://doi.org/10.1016/j.gaitpost.2023.11.024>
- [8] Sato, H., Berry, C. W., Peeri, Y., Baghoomian, E., Casey, B. E., Lavella, G., & Harrison, R. (2009). Remote radio control of insect flight. *Frontiers in Integrative Neuroscience*, 3(October). <https://doi.org/10.3389/neuro.07>
- [9] Tran-Ngoc, P. T., Le, D. L., Chong, B. S., Nguyen, H. D., Dung, V. T., Cao, F., Li, Y., Kai, K., Gan, J. H., Vo-Doan, T. T., Nguyen, T. L., & Sato, H. (2023). Intelligent Insect–Computer Hybrid Robot: Installing Innate Obstacle Negotiation and Onboard Human Detection onto Cyborg Insect. *Advanced Intelligent Systems*, 5(5). <https://doi.org/10.1002/aisy.202200319>
- [10] Triet, L. M., & Thinh, N. T. (2025). Behavior Modeling and Bio-Hybrid Systems: Using Reinforcement Learning to Enhance Cyborg Cockroach in Bio-Inspired Swarm Robotics. *IEEE Access*, 13(May), 100119–100148. <https://doi.org/10.1109/ACCESS.2025.3569285>
- [11] Urazayev, D., Eduard, A., Ahsan, M., & Zorbas, D. (2023). Indoor Performance Evaluation of ESP-NOW. 2023 IEEE International Conference on Smart Information Systems and Technologies (SIST), 1–6. <https://doi.org/10.1109/SIST58284.2023.10223585>