

Analisis Perbandingan Kinerja Arsitektur Unet Dan Yolo Untuk Deteksi Objek Pada Robot Sepak Bola Beroda

Haryan Dwi Baharna¹, Kurniabudi², Fachruddin^{2,*}

^{1,2,3} Fakultas Ilmu Komputer, Megister Sistem Informasi, Universitas Dinamika Bangsa, Jambi, Indonesia

Email: ¹haryandb@gmail.com, ²kbudiz@yahoo.com, ³fachruddin.stikom@gmail.com

Email Penulis Korespondensi: haryandb@gmail.com

Artikel Info :

Artikel History :

Submitted : 18-04-2025

Accepted : 09-06-2025

Published : 30-04-2026

Kata Kunci:

Segmentasi_Citra; U-Net; YOLOv11; Robot ; KRSBI; Deep_Learning

Abstrak— Perkembangan robotika semakin pesat, dengan robot yang semakin berperan dalam berbagai aktivitas manusia. Di Indonesia, kompetisi robot seperti Kontes Robot Sepak Bola Indonesia (KRSBI) kategori beroda diadakan setiap tahun sebagai bagian dari Kontes Robot Indonesia (KRI). KRSBI mengadopsi aturan dari RoboCup Middle Size League (MSL) dengan penyesuaian tertentu. Salah satu tantangan utama dalam kompetisi ini adalah kemampuan robot untuk mengenali dan merespons elemen-elemen di lapangan, seperti garis, robot lawan, dan bola, melalui segmentasi citra. Penelitian ini bertujuan untuk membandingkan kinerja dua arsitektur deep learning, yaitu U-Net dan YOLO, dalam melakukan segmentasi citra pada robot sepak bola beroda. U-Net, yang dikenal efektif dalam segmentasi gambar, terutama di bidang medis, diuji kemampuannya dalam mengenali objek lapangan, garis, robot, dan bola. Di sisi lain, YOLO, yang terkenal dengan kecepatan dan akurasi dalam deteksi objek real-time, juga dievaluasi untuk tugas yang sama. Hasil penelitian menunjukkan bahwa YOLO lebih unggul dalam mendeteksi objek bola dan robot dengan F1-score konsisten mencapai 1 di semua epoch (10, 50, dan 100), sementara UNet lebih baik dalam mendeteksi garis dan lapangan pada epoch awal. Namun, UNet memerlukan lebih banyak epoch untuk mencapai performa yang setara dengan YOLO dalam mendeteksi objek bola. Kesimpulan dari penelitian ini adalah bahwa pemilihan model harus disesuaikan dengan jenis objek yang akan dideteksi, dengan YOLO menjadi pilihan utama untuk deteksi bola dan robot, sedangkan UNet lebih cocok untuk deteksi garis dan lapangan jika waktu pelatihan yang lebih lama dapat ditoleransi.

Abstract— The field of robotics is advancing rapidly, with robots playing an increasingly significant role in various human activities. In Indonesia, robotic competitions such as the Wheeled Indonesian Soccer Robot Contest (KRSBI) are held annually as part of the Indonesian Robot Contest (KRI). KRSBI adopts rules from the RoboCup Middle Size League (MSL) with certain adjustments. One of the main challenges in this competition is the robot's ability to recognize and respond to elements on the field, such as lines, opposing robots, and the ball, through image segmentation. This study aims to compare the performance of two deep learning architectures, U-Net and YOLO, in performing image segmentation for wheeled soccer robots. U-Net, known for its effectiveness in image segmentation, particularly in the medical field, was tested for its ability to recognize field objects, lines, robots, and the ball. On the other hand, YOLO, renowned for its speed and accuracy in real-time object detection, was also evaluated for the same task. The results show that YOLO outperforms in detecting the ball and robots, with a consistent F1-score of 1 across all epochs (10, 50, and 100), while U-Net performs better in detecting lines and the field in the early epochs. However, U-Net requires more epochs to achieve performance comparable to YOLO in detecting the ball. The conclusion of this study is that the choice of model should be tailored to the type of object to be detected, with YOLO being the preferred choice for detecting the ball and robots, while U-Net is more suitable for detecting lines and the field if longer training times can be accommodated.

Keywords:

Image_Segmentation;
U-Net;YOLOv11;
Robots; KRSBI;
Deep_Learning

1. PENDAHULUAN

Perkembangan pada dunia robotika pada saat ini semakin pesat, di mana robot dapat berguna dalam setiap kegiatan manusia. Di Indonesia ajang kontes robot sudah dilakukan pada setiap tahunnya baik tingkat regional dan tingkat nasional. Salah satu kategori yang ingin dibahas dalam penelitian ini adalah kategori Kontes Robot Sepak Bola Indonesia (KRSBI) [1]. Kontes Robot Sepak Bola Indonesia (KRSBI) kategori beroda merupakan salah satu cabang kompetisi dalam Kontes Robot Indonesia (KRI) yang diadakan setiap tahun oleh Kementerian Riset, Teknologi, dan Pendidikan Tinggi [2]. Kompetisi KRSBI kategori beroda mengadopsi aturan dari RoboCup Middle Size League (MSL), sebuah turnamen robot sepak bola di tingkat internasional, dengan beberapa penyesuaian dengan aturan permainan sepak bola seperti ukuran lapangan dan jumlah robot yang berpartisipasi [3]. Lapangan KRSBI Beroda terdiri dari berbagai area yang memiliki fungsi dan karakteristik berbeda, serta garis-garis yang harus diikuti oleh robot.

Pemahaman tentang posisi robot lawan dan teman juga krusial untuk merencanakan strategi yang tepat, menghindari serangan, dan memanfaatkan peluang untuk mencetak gol. Dalam konteks robot sepak bola, segmentasi ini memungkinkan robot untuk mengenali area penting di lapangan, seperti robot, garis batas, dan bola, yang sangat penting untuk pengambilan keputusan dalam permainan, kemampuan ini sangat penting untuk memastikan bahwa robot dapat mengenali dan merespons elemen-elemen di lapangan dengan akurat [4], [5]. Beberapa cara agar robot mengenali objek di lapangan sepak bola beroda adalah dengan cara deteksi objek atau segmentasi citra [5], [6]. Segmentasi citra dalam pengolahan citra, bertujuan untuk memisahkan objek dari latar belakang dan membagi citra menjadi beberapa daerah berdasarkan atribut yang serupa [5].

Salah satu pendekatan yang telah banyak dilakukan ialah penggunaan *deep learning* untuk melakukan segmentasi, dalam *deep learning* untuk segmentasi adalah penggunaan *Convolutional Neural Networks* (CNN). CNN telah banyak diterima karena kemampuannya untuk mempelajari fitur hierarkis dari gambar, yang membuatnya sangat efektif untuk tugas seperti segmentasi semantik, di mana setiap piksel dalam gambar diklasifikasikan ke dalam kategori. Sebagai contoh, Litjens dkk. menekankan bahwa CNN telah secara signifikan meningkatkan kinerja dalam analisis citra medis, memfasilitasi tugas seperti segmentasi organ dan deteksi penyakit [7]. Beberapa metode segmentasi yang populer dalam *deep learning* antara lain *Fully Convolutional Networks* (FCN) [8], Segnet [9], U-Net [10], Mask R-CNN [11], DeepLab (DeepLabV3, DeepLabV3+) [12], SegNet [13] dan YOLO [14].

U-Net dikenal luas dalam bidang segmentasi gambar, terutama untuk aplikasi medis, karena arsitekturnya yang memungkinkan pemrosesan informasi spasial yang mendalam [15]. U-Net bekerja dengan cara menggabungkan fitur dari jalur kontraksi dan ekspansi, yang memungkinkan model ini untuk menghasilkan peta segmentasi yang akurat [14]. Dalam penelitian yang dilakukan oleh Szemenyei dan Estivill-Castro, mereka menunjukkan bahwa arsitektur UNet dapat diadaptasi untuk tugas segmentasi objek dalam konteks robot sepak bola, di mana akurasi dan efisiensi komputasi sangat penting, hasil dari penelitian ini mendapatkan nilai IoU sebesar 79.97% dan meningkat menjadi 83.28% ketika dimodifikasi menjadi Robo U-Net V2 [16].

Di sisi lain, YOLO (*You Only Look Once*) telah berkembang menjadi salah satu metode deteksi objek yang paling efisien dan cepat. Versi terbaru dari YOLO, seperti YOLOv5 dan YOLOv8, tidak hanya mampu mendeteksi objek, tetapi juga dapat melakukan *segmentasi instance*, yang memungkinkan pemisahan objek dalam gambar dengan lebih akurat [17]. Penelitian menunjukkan bahwa YOLO dapat mencapai tingkat presisi yang tinggi dalam deteksi dan segmentasi objek, dengan beberapa model menunjukkan akurasi 98% [17]. Dalam konteks robot sepak bola, kemampuan YOLO untuk melakukan deteksi dan segmentasi secara real-time sangat penting untuk pengambilan keputusan yang cepat selama pertandingan [18].


Saat ini, deteksi objek pada robot KRSBI Beroda masih banyak menggunakan metode berbasis HSV (*Hue, Saturation, Value*) [19], [20], [21]. Pendekatan HSV sering terpengaruh oleh kondisi pencahayaan dan warna latar belakang, yang menyebabkan ketidakakuratan dalam deteksi objek. Contohnya, Himmah dkk menyatakan bahwa perubahan ringan dalam kondisi pencahayaan dapat mempengaruhi hasil klasifikasi berdasarkan warna, membuat model HSV kurang robust dalam situasi nyata yang dinamis [22]. Selain itu, teknik ini sering kali mengandalkan konversi citra dan pengolahan manual untuk mengekstrak fitur, yang dapat memakan waktu dan berpotensi menyebabkan kehilangan informasi penting dalam citra yang kompleks [23]. Pendekatan *deep learning* cenderung memberikan akurasi yang lebih tinggi dibandingkan dengan metode HSV karena model-model ini dirancang untuk memperhatikan interaksi fitur yang kompleks dalam piksel citra [24]. Misalnya, dalam studi tentang klasifikasi kematangan buah, penggunaan CNN memberikan performa yang lebih baik dalam efisiensi klasifikasi dibandingkan hanya menggunakan ekstraksi fitur dari warna [25].

Berdasarkan latar belakang yang telah dijelaskan, diperlukan sebuah metode untuk meningkatkan kemampuan robot dalam memahami lingkungan kompetisi, khususnya dalam segmentasi area lapangan pada robot sepak bola beroda. Segmentasi yang akurat dapat membantu robot dalam mengikuti aturan permainan dan menentukan strategi yang lebih baik. Dalam hal ini, penelitian ini tertarik untuk membandingkan metode segmentasi menggunakan arsitektur U-Net dan YOLO pada robot sepak bola beroda dalam konteks segmentasi area lapangan, garis, robot, dan bola. Kedua model memiliki pendekatan yang berbeda dan keunggulan masing-masing dalam segmentasi citra, yang relevan dengan kebutuhan robot untuk memahami lingkungan secara akurat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Eksperimen penelitian yang dilakukan untuk segmentasi lapangan, garis, robot, dan bola menggunakan YOLO dan UNet memiliki alur yang jelas sebagaimana ditunjukkan pada Gambar 1.

**Gambar 1.** Alur eksperimen

Gambar 1 menunjukkan alur eksperimen yang terdiri dari beberapa tahap utama, dimulai dari persiapan data, pengembangan model deteksi, *training*, evaluasi. Penjelasan masing-masing tahapan eksperimen dijelaskan sebagai berikut.

1. Persiapan Data

Di mana langkah-langkah seperti pengumpulan, pelabelan, dan pembagian dataset dilakukan. Data dikumpulkan dari hasil pengambilan sendiri, kemudian dilabeli sesuai kebutuhan. Baik untuk YOLO maupun UNet, pelabelan dilakukan dalam bentuk segmentasi mask untuk memberi label pada setiap piksel di gambar sesuai kategori seperti lapangan, garis, robot, atau bola. Setelah data diproses, dataset dibagi menjadi tiga bagian: pelatihan, validasi, dan pengujian, umumnya pembagian dataset dibagi menjadi 70% untuk pelatihan, 20% validasi, dan 10% pengujian [26], [27].

2. Pengembangan Model Deteksi

Dalam penelitian ini, menggunakan dua arsitektur utama, yaitu YOLO dan UNet, yang keduanya digunakan untuk segmentasi. YOLO diterapkan untuk segmentasi objek seperti robot dan bola dengan fokus pada area tertentu, sedangkan UNet digunakan untuk segmentasi area seperti lapangan dan garis dengan tingkat detail yang lebih tinggi pada setiap piksel. Pengembangan kedua arsitektur ini melibatkan penyesuaian parameter model, desain struktur jaringan, serta preprocessing data yang disesuaikan dengan karakteristik masing-masing metode.

3. *Training*

Model YOLO dilatih untuk melakukan segmentasi objek seperti lapangan, garis, robot, bola, dan lapangan, sementara model UNet dilatih untuk segmentasi berbasis piksel pada kategori yang sama. Selama proses pelatihan, melakukan penyesuaian *hyperparameter* seperti *learning rate* dan *optimizer* guna memaksimalkan performa dari masing-masing model.

4. Evaluasi

Tahap evaluasi bertujuan untuk mengukur performa model dalam melakukan segmentasi objek. Peneliti menggunakan metrik seperti *Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *Intersection over Union* (IoU) untuk menilai kinerja model. *Accuracy* digunakan untuk mengukur sejauh mana prediksi model secara keseluruhan sesuai dengan *label ground truth*. *Precision* dan *Recall* digunakan untuk mengevaluasi kemampuan model dalam mengidentifikasi kategori tertentu secara akurat, sementara *F1-Score* memberikan keseimbangan antara *Precision* dan *Recall*. Selain itu, IoU digunakan untuk mengukur tingkat kesesuaian antara area prediksi segmentasi dan *label ground truth* pada setiap piksel. Evaluasi ini menghasilkan data kuantitatif yang memungkinkan peneliti untuk membandingkan keunggulan masing-masing model dalam menyelesaikan tugas segmentasi secara komprehensif.

3. HASIL DAN PEMBAHASAN


3.1 Hasil Penelitian

3.1.1 Persiapan Data

Di mana pada tahapan persiapan data langkah-langkah seperti pengumpulan, pelabelan, dan pembagian dataset dilakukan. Data dikumpulkan dari hasil pengambilan sendiri, kemudian dilabeli sesuai kebutuhan.

1. Pengumpulan Dataset


Dalam penelitian ini, data diambil dari kamera omni yang terpasang pada robot sepak bola beroda. Kamera ini menangkap gambar dengan sudut pandang 360 derajat, memberikan perspektif menyeluruh terhadap lingkungan sekitar robot. Video yang dihasilkan diambil sebanyak tiga frame per detik untuk memperoleh informasi citra yang cukup dan representatif. Setiap frame diekspor dalam format PNG untuk mempermudah analisis, menghasilkan 2646 gambar dengan berbagai kondisi pencahayaan dan sudut pandang. Setelah seleksi berdasarkan kejelasan objek, diperoleh 800 frame berkualitas baik yang digunakan sebagai data utama untuk analisis selanjutnya. Hasil seleksi ditampilkan pada Gambar 2.



Gambar 2. Hasil foto perframe dari video


2. Anotasi Data (Labelling)

Anotasi adalah proses pelabelan objek dalam gambar untuk pelatihan machine learning. Penelitian ini menggunakan Roboflow, platform anotasi populer yang memudahkan penambahan label dan bounding box. Hasil anotasi disimpan dalam format YOLO. Hasil image yang telah diberi label dapat dilihat pada Gambar 3.



Gambar 3. Image yang telah diberi label

Dari proses anotasi ini, diperoleh jumlah masing-masing elemen: lapangan sebanyak 3.197, bola 768, garis 1.708, dan robot 900. Jumlah dataset untuk masing-masing class dapat dilihat pada Gambar 4.




Gambar 4. Jumlah dataset

Kemudian dilakukan proses *preprocessing* dataset gambar yang terdiri dari 800 citra, setiap gambar diubah ukurannya (*resize*) dengan metode *fit* ke dalam resolusi 640x640 piksel, sehingga menjaga aspek rasio asli gambar dengan menambahkan tepi hitam (*black edges*). Setelah itu, dataset dibagi menjadi tiga bagian: *train* (70%) sebanyak 560 gambar, *validation* (20%) sebanyak 160 gambar, dan *test* (10%) sebanyak 80 gambar. Selanjutnya, data pelatihan (*train*) dilakukan augmentasi dengan transformasi *horizontal flip* dan *vertical flip*, yang diterapkan pada seluruh 560 gambar, menghasilkan total 968 gambar untuk meningkatkan keberagaman data tanpa mengubah jumlah data validasi dan pengujian.

3.1.2 Pelatihan Model

Berikut adalah visualisasi dari hasil pelatihan model YOLO menggunakan epoch 100 dapat dilihat pada Gambar 5.



Gambar 5. Visualisasi Perbandingan *Loss* selama pelatihan YOLO dan UNET Epoch 100

Berdasarkan hasil pelatihan pada Gambar 5 selama 100 *epoch*, dapat disimpulkan bahwa kedua model menunjukkan performa yang baik dalam menyegmentasi objek. Model YOLO mengalami penurunan *loss* yang signifikan dan mencapai konvergensi setelah 100 *epoch*, dengan nilai mAP50 yang stabil di sekitar 0.8 setelah 50 *epoch*. Sementara itu, model U-Net menunjukkan performa yang lebih tinggi, dengan *loss* yang terus menurun hingga mendekati nilai minimum dan mAP50 yang mencapai sekitar 0.9 setelah 20 *epoch*. Stabilitas performa pada kedua model menunjukkan bahwa mereka telah berhasil mempelajari pola data dengan baik. Namun, model U-Net terlihat memiliki akurasi yang lebih tinggi dibandingkan YOLO dalam tugas segmentasi berdasarkan metrik yang diperoleh.

Berikut adalah tabel *confusion matrix* yang diperoleh dari hasil perhitungan pada *epoch* 100 yang dapat dilihat pada Tabel 1.

Tabel 1. *Confusion Matrix* YOLO dan UNET Epoch 100

Model	Aktual/Prediksi	Bola	Garis	Lapangan	Robot	Background
YOLO	Bola	49	0	0	0	0
	Garis	0	46	2	0	22
	Lapangan	0	13	218	0	173
	Robot	0	0	0	63	3
	Background	0	43	16	9	0
UNET	Bola	46	0	0	0	1
	Garis	0	63	7	0	6
	Lapangan	0	0	255	0	5
	Robot	0	0	0	60	8
	Background	0	0	1	0	122

Berdasarkan Tabel 1 *Confusion Matrix* model UNET menunjukkan performa yang lebih baik secara keseluruhan dibandingkan YOLO, terutama dalam mendeteksi lapangan, garis, dan *background*. UNET berhasil mengklasifikasikan lapangan dengan akurasi tinggi (255 benar dengan hanya 5 kesalahan) serta memiliki kesalahan yang lebih sedikit dibandingkan YOLO dalam mengenali garis dan *background*. Sementara itu, YOLO unggul dalam mendeteksi bola dan robot dengan tingkat akurasi tinggi, tetapi mengalami lebih banyak kesalahan dalam mengklasifikasikan garis dan lapangan, yang sering salah dikenali sebagai *background*. YOLO juga

menunjukkan tingkat kesalahan yang lebih tinggi dalam mengklasifikasikan *background* ke dalam kelas lain, seperti garis dan lapangan. Dengan demikian, jika tujuan utama adalah mendeteksi lapangan dan garis dengan presisi tinggi, UNET lebih direkomendasikan. Namun, jika fokus utama adalah deteksi bola dan robot, YOLO masih menjadi pilihan yang baik.

3.2 Pembahasan

Setelah proses pelatihan dilakukan pada masing-masing *class*, perbandingan performa antara model YOLO dan UNET dapat dilihat pada Tabel 2.

Tabel 2. Hasil performa model per *class*

Model	Epoch	F1-Score			
		Bola	Garis	Lapangan	Robot
YOLO	10	0.9245	0.3564	0.6370	0.9091
	50	1.0000	0.4756	0.6971	0.7482
	100	1.0000	0.5349	0.6813	0.9130
UNET	10	0.0000	0.9041	0.9655	0.8871
	50	0.7934	0.9932	0.9484	0.8980
	100	0.9892	0.9065	0.9751	0.9375

Berdasarkan hasil pengujian yang disajikan pada **Error! Reference source not found.**, model yolo dan unet memiliki keunggulan masing-masing tergantung pada kelas objek yang dideteksi.

1. Kelas Bola

YOLO menunjukkan performa yang sangat baik dalam mendeteksi "Bola" dengan nilai F1-Score mencapai 1.000 pada *epoch* 50 dan 100, serta 0.9245 pada *epoch* 10. Sebaliknya, UNET memiliki performa rendah pada *epoch* 10 (0.0000) namun meningkat secara signifikan hingga mencapai 0.9892 pada *epoch* 100. Hal ini menunjukkan bahwa YOLO lebih stabil dalam mendeteksi bola sejak *epoch* awal, sedangkan UNET memerlukan lebih banyak *epoch* untuk mencapai performa optimal.

2. Kelas Garis

UNET unggul dalam mendeteksi "Garis" dengan nilai F1-Score yang tinggi sejak *epoch* 10 (0.9041), mencapai nilai tertinggi pada *epoch* 50 (0.9932), dan sedikit menurun pada *epoch* 100 (0.9065). Sementara itu, YOLO mengalami peningkatan bertahap dari 0.3564 pada *epoch* 10, 0.4756 pada *epoch* 50, hingga mencapai 0.5349 pada *epoch* 100. Dengan demikian, UNET lebih baik dalam mendeteksi garis dibandingkan YOLO pada seluruh *epoch*.

3. Kelas Lapangan

Untuk deteksi "Lapangan," UNET menunjukkan performa lebih tinggi dibanding YOLO di semua *epoch*. Pada *epoch* 10, 50, dan 100, UNET mencapai nilai F1-Score masing-masing 0.9655, 0.9484, dan 0.9751. Sementara itu, YOLO memiliki nilai yang lebih rendah, yaitu 0.6370 pada *epoch* 10, meningkat menjadi 0.6971 pada *epoch* 50, namun sedikit menurun menjadi 0.6813 pada *epoch* 100. Ini menunjukkan bahwa UNET lebih andal dalam mendeteksi lapangan dibandingkan YOLO.

4. Kelas Robot

Dalam mendeteksi "Robot," kedua model menunjukkan performa yang baik. YOLO memiliki nilai F1-Score yang relatif tinggi dan stabil (0.9091 pada *epoch* 10, 0.7482 pada *epoch* 50, dan 0.9130 pada *epoch* 100). UNET juga menunjukkan performa yang baik dengan nilai 0.8871 pada *epoch* 10, meningkat menjadi 0.8980 pada *epoch* 50, dan mencapai 0.9375 pada *epoch* 100. Dengan demikian, keduanya mampu mendeteksi robot dengan baik, meskipun UNET menunjukkan peningkatan performa yang lebih konsisten dibandingkan YOLO.

Kemudian hasil perbandingan performa dari model YOLO dan UNET dapat dilihat pada Tabel 3.

Tabel 3. Hasil performa model YOLO dan UNET

Model	Epoch	Accuracy	Precision	Recall	F1-Score
YOLO	10	0.9381	0.9494	0.9258	0.9320
UNET	10	0.9764	0.7333	0.7295	0.7313
YOLO	50	0.9692	0.9469	0.9777	0.9605
UNET	50	0.9383	0.8998	0.9684	0.9281
YOLO	100	0.9616	0.9426	0.9755	0.9566
UNET	100	0.9838	0.9933	0.9750	0.9835

Berdasarkan hasil pengujian yang disajikan dalam Tabel 3, performa model YOLO dan UNET menunjukkan keunggulan masing-masing pada berbagai metrik evaluasi. Pada *epoch* 10, UNET memiliki akurasi lebih tinggi (0.9764) dibanding YOLO (0.9381), tetapi memiliki nilai *precision*, *recall*, dan *F1-score* yang lebih rendah. Pada *epoch* 50, YOLO mengalami peningkatan signifikan dengan nilai *F1-score* tertinggi (0.9605), sedangkan UNET menunjukkan peningkatan pada *precision* dan *recall* dengan *F1-score* sebesar 0.9281. Pada *epoch* 100, UNET mencapai performa terbaiknya dengan akurasi tertinggi (0.9838) dan *F1-score* 0.9835, sedikit lebih baik dibanding YOLO yang memiliki *F1-score* 0.9566. Secara keseluruhan, YOLO menunjukkan performa yang lebih stabil sejak awal dengan *precision* dan *recall* yang lebih seimbang, sementara UNET membutuhkan lebih banyak *epoch* untuk mencapai akurasi dan *F1-score* yang optimal.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model deteksi objek menggunakan arsitektur UNET dan YOLO untuk segmentasi citra area lapangan KRSBI Beroda. Kedua model mampu mendeteksi objek-objek utama seperti bola, garis, lapangan, dan robot dengan tingkat akurasi yang bervariasi tergantung pada kelas objek dan jumlah *epoch* yang digunakan. YOLO unggul dalam mendeteksi objek bola dan robot dengan *F1-score* tinggi dan stabil di berbagai *epoch*. Dari segi metrik keseluruhan, YOLO memiliki performa yang lebih stabil sejak *epoch* awal, dengan nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang relatif tinggi. Pada *epoch* 10, YOLO mencapai *accuracy* 0.9381 dan *F1-score* 0.9320, sedangkan UNET memiliki *accuracy* lebih tinggi (0.9764) tetapi *F1-score* lebih rendah (0.7313). Namun, seiring bertambahnya *epoch*, UNET menunjukkan peningkatan yang lebih signifikan dan pada *epoch* 100 mencapai *accuracy* tertinggi (0.9838) dengan *F1-score* 0.9835, melampaui YOLO yang memiliki *F1-score* 0.9566. Hasil penelitian ini menunjukkan bahwa pemilihan model deteksi objek harus disesuaikan dengan jenis objek yang akan dideteksi serta jumlah *epoch* yang digunakan. Jika tujuan utama adalah mendeteksi bola dan robot, maka YOLO menjadi pilihan yang lebih baik karena memiliki *F1-score* yang lebih tinggi dan stabil sejak *epoch* awal. Namun, jika fokus utama adalah pada deteksi garis dan lapangan, maka UNET lebih unggul, terutama setelah jumlah *epoch* yang lebih banyak. Selain itu, jika akurasi keseluruhan menjadi prioritas utama dan waktu pelatihan yang lebih lama tidak menjadi kendala, UNET dapat menjadi pilihan yang lebih optimal dibandingkan YOLO.

REFERENCES

- [1] T. H. Ata and H. Soebhakti, "A Penerapan Kontrol PID dalam Penggiring Bola pada Robot Sepak Bola Beroda," *Journal of Applied Electrical Engineering*, vol. 8, no. 1, pp. 70–77, Jun. 2024, doi: 10.30871/jaee.v8i1.7463.
- [2] F. Dzil, Agus Khumaidi, Mohammad Basuki Rahmat, Joko Endrasmono4, Mat Syai'in, and Dimas Pristovani Riananda, "Deteksi Objek di Lapangan pada Robot Sepakbola Beroda Menggunakan Metode YOLOV5," *Jurnal Elektronika dan Otomasi Industri*, vol. 11, no. 2, pp. 604–611, Jul. 2024, doi: 10.33795/elkolind.v11i2.5235.
- [3] F. Dzil, Agus Khumaidi, Mohammad Basuki Rahmat, Joko Endrasmono4, Mat Syai'in, and Dimas Pristovani Riananda, "Deteksi Objek di Lapangan pada Robot Sepakbola Beroda Menggunakan Metode YOLOV5," *Jurnal Elektronika dan Otomasi Industri*, vol. 11, no. 2, pp. 604–611, Jul. 2024, doi: 10.33795/elkolind.v11i2.5235.

- [4] A. A. Wahyudi, Agus Khumaidi, Mohammad Basuki Rahmat, Dimas Pristovani Riananda, Mat Syai'in, and Joko Endrasmono, "Implementasi Robot Operating System (ROS) Untuk Meningkatkan Akurasi Deteksi Bola Menggunakan YOLO V5 Pada KRSBI-Beroda," *Jurnal Elektronika dan Otomasi Industri*, vol. 11, no. 2, pp. 648–661, Jul. 2024, doi: 10.33795/elkolind.v11i2.5234.
- [5] A. A. R. Stone, N. Suciati, and D. A. Navastara, "Segmentasi Citra pada Robot Sepak Bola Beroda Menggunakan Multilayer Neural Network dan Fitur Warna HSV," *Jurnal Teknik ITS*, vol. 7, no. 2, pp. A276–A281, Dec. 2018, doi: 10.12962/j23373539.v7i2.33741.
- [6] R. A. Fatekha, B. S. B. Dewantara, and H. Oktavianto, "Sistem Deteksi Bola pada Robot Kiper Pemain Sepakbola Beroda," *JURNAL INTEGRASI*, vol. 13, no. 2, pp. 127–134, Nov. 2021, doi: 10.30871/ji.v13i2.3133.
- [7] G. Litjens *et al.*, "A survey on deep learning in medical image analysis," *Med Image Anal*, vol. 42, pp. 60–88, Dec. 2017, doi: 10.1016/j.media.2017.07.005.
- [8] O. OZTURK, B. SARITÜRK, and D. Z. SEKER, "Comparison of Fully Convolutional Networks (FCN) and U-Net for Road Segmentation from High Resolution Imageries," *International Journal of Environment and Geoinformatics*, vol. 7, no. 3, pp. 272–279, Dec. 2020, doi: 10.30897/ijgeo.737993.
- [9] V. Badrinarayanan, A. Kendall, and R. Cipolla, "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 12, pp. 2481–2495, Dec. 2017, doi: 10.1109/TPAMI.2016.2644615.
- [10] A. A. Pravitasari *et al.*, "UNet-VGG16 with transfer learning for MRI-based brain tumor segmentation," *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, vol. 18, no. 3, p. 1310, Jun. 2020, doi: 10.12928/telkomnika.v18i3.14753.
- [11] R. Budi, R. A. Harianto, and E. Setyati, "Segmentasi Citra Area Tumpukan Sampah Dengan Memanfaatkan Mask R-CNN," *Journal of Intelligent System and Computation*, vol. 5, no. 1, pp. 58–64, Apr. 2023, doi: 10.52985/insyst.v5i1.305.
- [12] C. Raras, P. Setiawan, and D. Komarasary, "Pengaruh Segmentasi terhadap Diagnosis COVID-19 pada Citra X-Ray Paru," *CogITo Smart Journal*, vol. 9, no. 1, pp. 171–180, 2023.
- [13] I. S. Ardan and R. Indraswari, "Sistem Berbasis Deep Learning untuk Segmentasi dan Klasifikasi Tingkat Keganasan Tumor Otak Menggunakan Citra MRI 3D," *ILKOMNIKA: Journal of Computer Science and Applied Informatics*, vol. 6, no. 2, pp. 1–10, 2024.
- [14] J. Fu, J.-W. Chai, P.-L. Chen, Y.-W. Ding, and H.-C. Chen, "Quantitative measurement of spinal cerebrospinal fluid by cascade artificial intelligence models in patients with spontaneous intracranial hypotension," *Biomedicine*, vol. 10, no. 8, p. 2049, 2022.
- [15] J. Pan, "Image Segmentation Based On U-Net and Adjusted U-Nets," *Highlights in Science, Engineering and Technology*, vol. 85, pp. 316–327, 2024.
- [16] M. Szemenyei and V. Estivill-Castro, "Fully neural object detection solutions for robot soccer," *Neural Comput Appl*, vol. 34, no. 24, pp. 21419–21432, 2022.
- [17] X. Chen, P. Shi, and Y. Hu, "A precise semantic segmentation model for seabed sediment detection using yolo-c," *J Mar Sci Eng*, vol. 11, no. 7, p. 1475, 2023.
- [18] M. Szemenyei and V. Estivill-Castro, "Fully neural object detection solutions for robot soccer," *Neural Comput Appl*, vol. 34, no. 24, pp. 21419–21432, 2022.
- [19] T. Nurochman, N. S. Widodo, and K. Firdausy, "Sistem Pengenalan Bola dan Gawang Pada Robot Sepakbola Beroda Berbasis Mesin Visi," in *Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*, 2018.
- [20] J. Sahertian and M. M. Verlianto, "Sistem Pendeteksian Bola Pada Robot Sepakbola Beroda Berbasis Filter Warna," in *Prosiding Seminar Nasional Teknologi Informasi dan Komunikasi (SENATIK)*, 2019, pp. 116–119.
- [21] A. A. R. Stone, N. Suciati, and D. A. Navastara, "Segmentasi Citra pada Robot Sepak Bola Beroda Menggunakan Multilayer Neural Network dan Fitur Warna HSV," *Jurnal Teknik ITS*, vol. 7, no. 2, pp. A276–A281, 2018.
- [22] E. F. Himmah, M. Widyaningsih, and M. Maysaroh, "Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering," *Jurnal Sains dan Informatika*, vol. 6, no. 2, pp. 193–202, Dec. 2020, doi: 10.34128/jsi.v6i2.242.
- [23] M. F. Naufal, "Analisis Perbandingan Algoritma Svm, Knn, Dan Cnn untuk Klasifikasi Citra Cuaca.," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 2, pp. 311–317, 2021.
- [24] A. Peryanto, A. Yudhana, and R. Umar, "Rancang bangun klasifikasi citra dengan teknologi deep learning berbasis metode convolutional neural network," *Format J. Ilm. Tek. Inform*, vol. 8, no. 2, p. 138, 2020.
- [25] Y. Mardianto, T. Dewi, and P. Risma, "Analisis Klasifikasi Kematangan Buah Tomat dengan Pendekatan Transfer Learning Model EfficientNet," *Techno Bahari*, vol. 11, no. 1, pp. 20–25, 2024.

- [26] W. Kurdthongmee, "A comparative study of the effectiveness of using popular DNN object detection algorithms for pith detection in cross-sectional images of parawood," *Heliyon*, vol. 6, no. 2, Feb. 2020, doi: 10.1016/j.heliyon.2020.e03480.
- [27] R. Putra, M. Maimunah, and D. Sasongko, "Implementasi Algoritma YOLO V8 (You Only Look Once) Dalam Deteksi Penyakit Daun Durian," *Building of Informatics, Technology and Science (BITS)*, vol. 6, no. 3, Dec. 2024, doi: 10.47065/bits.v6i3.6136.