

BAB V

PENUTUP

5.1 KESIMPULAN

Berdasarkan hasil pembahasan analisis terhadap model YOLO dan UNET dalam perbandingan segmentasi, dapat disimpulkan sebagai berikut

1. Pengembangan Model Deteksi Objek

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.

2. Kinerja YOLO dan U-Net

YOLO unggul dalam mendeteksi objek bola dan robot dengan *F1-score* tinggi dan stabil di berbagai *epoch*. Pada kelas bola, YOLO mencapai *F1-score* sempurna (1.0000) pada *epoch* 50 dan 100, sementara UNET membutuhkan lebih banyak *epoch* untuk mencapai 0.9892 pada *epoch* 100. Untuk kelas robot, performa YOLO sedikit berfluktuasi (0.9091 di *epoch* 10, turun ke 0.7482 di *epoch* 50, lalu meningkat ke 0.9130 di *epoch* 100), sedangkan UNET menunjukkan peningkatan stabil dari 0.8871 di *epoch* 10 menjadi 0.9375 di *epoch* 100. Sebaliknya, UNET lebih unggul dalam mendeteksi garis dan lapangan, dengan *F1-score* lebih tinggi sejak awal pada kelas garis (0.9041 di *epoch* 10, puncak 0.9932 di *epoch* 50, dan 0.9065 di *epoch* 100), sementara YOLO meningkat perlahan dari 0.3564 di *epoch*

10 ke 0.5349 di *epoch* 100. Untuk kelas lapangan, UNET mempertahankan keunggulannya dengan *F1-score* 0.9655 di *epoch* 10, sedikit menurun ke 0.9484 di *epoch* 50, lalu naik kembali ke 0.9751 di *epoch* 100, sedangkan YOLO memiliki performa lebih rendah (0.6370 di *epoch* 10, 0.6971 di *epoch* 50, dan 0.6813 di *epoch* 100), menunjukkan keterbatasannya dalam mendeteksi lapangan dibandingkan UNET.

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.

3. Implikasi Praktis

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.

5.2 SARAN

Berdasarkan hasil penelitian yang telah dilakukan mengenai Perbandingan Kinerja Arsitektur Unet Dan Yolo Untuk Deteksi Objek, terdapat beberapa temuan yang dapat dijadikan dasar untuk pengembangan lebih lanjut, maka penulis menyarankan sebagai berikut:

1. Untuk meningkatkan generalisasi model, disarankan menggunakan *dataset* yang lebih besar dan beragam, termasuk variasi kondisi pencahayaan, sudut pandang, dan gangguan visual lainnya yang mungkin terjadi di lapangan KRSBI Beroda.
2. Selain YOLO dan U-Net, disarankan untuk mengeksplorasi arsitektur *deep learning* lainnya seperti Mask R-CNN, DeepLabV3+, atau *Transformer-based models* (misalnya, *Vision Transformers*) untuk melihat apakah ada peningkatan performa yang signifikan.