

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Dari hasil implementasi sistem serta pengujian yang telah dilakukan yang dilihat dari beberapa aspek serta *evaluation metrics* yang sudah ditentukan di awal, ternyata model YOLOv7-tiny masih lebih unggul secara keseluruhan meskipun selisihnya tidak begitu jauh dari segi performa untuk akurasi dan *inference speed*-nya yang rata-rata hanya berbeda $\pm 3-5\%$ saja. Jika melihat *improvement* yang dilakukan seharusnya selisih tersebut bisa lebih tinggi, apalagi dari segi akurasi yang sebagaimana dijelaskan YOLOv7 menggunakan *model scaling* pada arsitekturnya yang membuat model ini dapat beradaptasi dengan *input* sampel dengan ukuran yang berbeda-beda (besar dan kecil) sehingga harusnya bisa lebih *robust* dan akurat tentunya. Namun seperti yang bisa dilihat dari hasil pada penelitian ini, model YOLOv7 khususnya YOLOv7-tiny tidak begitu memberikan perbedaan performa yang begitu signifikan untuk aspek performa akurasi dan *speed*-nya. Berbeda dengan hasil yang ditunjukkan pada jurnal resminya yang menunjukkan selisih hingga 120% (*speed*) dan 56.8% (*accuracy*). Dan jika mengacu pada hasil yang ditunjukkan jurnal [10], di mana YOLOv7 terlihat memiliki performa yang lebih rendah dari YOLOv5 ketika diuji dengan *dataset* yang berbeda dengan yang digunakan untuk *train*, hal ini dapat berarti bahwa YOLOv7 sangat bergantung pada kualitas dan jenis *dataset* yang digunakan.

Kesalahan deteksi pun terlihat masih banyak terjadi pada kedua model dengan nilai *confidence* yang cukup tinggi, meskipun dalam hal ini kesalahan prediksi yang dibuat oleh YOLOv7 masih dapat ditolerir karena mendeteksi objek pada kendaraan yang berupa tulisan/stiker/bagian yang berbentuk kotak sebagai plat nomor. Berbeda halnya dengan YOLOv5 yang mendeteksi bagian *random* pada *input* sebagai plat nomor. Hal ini jika dilihat dari kurva *loss* keduanya, sebenarnya memiliki tingkat *loss* yang kecil, dengan catatan model YOLOv5s memiliki kurva yang lebih stabil dibanding YOLOv7-tiny yang menunjukkan adanya fluktuasi.

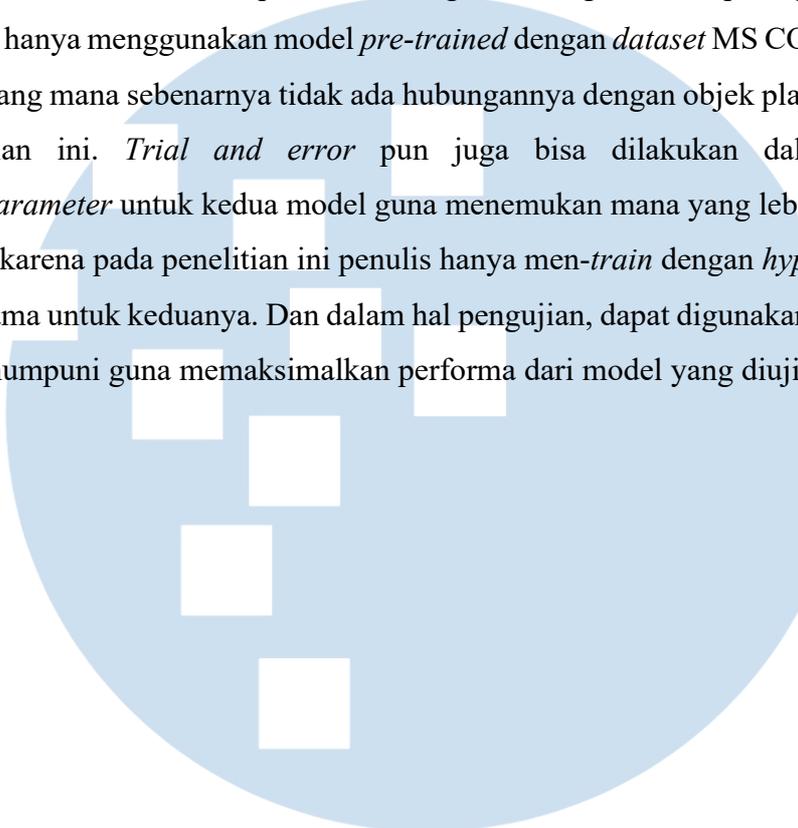
Dari sisi efisiensi, YOLOv7-tiny memiliki waktu *train* yang jauh lebih cepat yakni ± 5 jam dengan *hyperparameter* dan *environment* pengujian yang sama antar kedua model. Terbukti bahwa penggunaan E-ELAN (*Extended Efficient Layer Aggregation*) pada *backbone* dapat mengurangi *memory cost* sehingga membuatnya menjadi lebih efisien dan komputasinya menjadi lebih cepat. Untuk *testing* keduanya serupa yakni hanya berbeda 1 detik saja dengan YOLOv5s lebih unggul.

Dapat disimpulkan dari beberapa hasil yang diperoleh pada penelitian ini, untuk pendeteksian secara *real-time* dengan objeknya yang berupa plat nomor pada kendaraan roda empat di jalan, dengan jumlah total *dataset* sebanyak 3636 sampel model *object detection* YOLOv7-tiny secara *overall performance* lebih unggul dibanding YOLOv5s. Dari hasil terlihat bahwa selain memiliki waktu *train* yang lebih cepat dan ukuran model yang lebih kecil, model ini juga memiliki akurasi dan *balance* (*F1-score*) yang lebih tinggi meskipun tidak berbeda jauh di mana YOLOv7-tiny memperoleh nilai $mAP@0.5$ sebesar 0.897 atau 90% dan $mAP@0.5:0.95$ sebesar 0.492 atau 49%, sedangkan untuk model YOLOv5s nilai $mAP@0.5$ berada di 0.856 atau 86% dan $mAP@0.5:0.95$ pada 0.438 atau 44%. Sehingga model yang direkomendasikan untuk digunakan dalam kasus pendeteksian objek plat nomor khususnya dengan format Indonesia secara *real-time*, adalah YOLOv7-tiny.

5.2 Saran

Dalam upaya untuk meningkatkan performa model yang digunakan, baik untuk YOLOv5 ataupun YOLOv7 perlu memperhatikan komposisi *dataset* yang digunakan dan lebih detail untuk tiap kondisi atau *constraint* yang ingin digunakan (berdasarkan jenis plat, warna, perspektif). Karena pada penelitian ini sampelnya cenderung menggunakan plat nomor berwarna hitam dengan format yang umum sehingga memiliki performa yang buruk ketika dihadapkan dengan plat nomor berwarna lain atau format lain (kuning, merah, putih, TNI, Polri). Perihal *augmentasi dataset* juga bisa menjadi pertimbangan untuk lebih lagi meningkatkan *robustness* suatu model, pemilihannya juga disesuaikan dengan kondisi riil atau

dengan kata lain kontekstual. Selain itu tentu *fine-tuning* juga dapat dilakukan agar performa sebuah model dapat lebih ditingkatkan lagi, karena pada penelitian ini penulis hanya menggunakan model *pre-trained* dengan *dataset* MS COCO (bawaan repo) yang mana sebenarnya tidak ada hubungannya dengan objek plat nomor pada penelitian ini. *Trial and error* pun juga bisa dilakukan dalam men-*set hyperparameter* untuk kedua model guna menemukan mana yang lebih cocok atau sesuai, karena pada penelitian ini penulis hanya men-*train* dengan *hyperparameter* yang sama untuk keduanya. Dan dalam hal pengujian, dapat digunakan *device* yang lebih mumpuni guna memaksimalkan performa dari model yang diuji.

A large, light blue watermark logo of Universitas Multimedia Nusantara (UMMN) is centered on the page. It features a stylized 'U' with a grid of squares inside, and the letters 'M' and 'N' to its right.

UMMN

UNIVERSITAS
MULTIMEDIA
NUSANTARA