

berbeda. Jika hasil penghitungan F_0 dari suatu faktor lebih besar sama dengan F tabel, maka Hipotesis 0 harus ditolak atau Hipotesis alternatif nya diterima yang artinya terdapat perbedaan pengaruh faktor yang signifikan terhadap hasil.

Berdasarkan tabel F , diperoleh bahwa F tabel berdasarkan probabilitas 0,05 dengan derajat kebebasan 1 & 138 adalah 3,91. Sehingga, jika mengacu kepada tabel di atas, F hitung dari keseluruhan faktor memiliki nilai yang lebih besar F tabel. Artinya, seluruh faktor memiliki pengaruh yang signifikan terhadap nilai mAP50 pada deteksi baut dengan algoritma YOLO. Sedangkan, pengaruh terbesar dari keseluruhan faktor merupakan faktor D (*Weight Decay*) dengan persentase kontribusi sebesar 59.36%. Hal ini sesuai dengan hasil *Main Effect Analysis* yang menunjukkan bahwa faktor yang paling berpengaruh terhadap rata-rata mAP50 untuk tingkat akurasi deteksi baut menggunakan algoritma YOLO yaitu *Weight Decay*.

4.2.3. Uji Performansi YOLO Berdasarkan Faktor Level Optimum

Berdasarkan *Main Effect Analysis*, diketahui faktor level apa saja yang dapat memberikan nilai performansi lebih baik. Pada tahap ini, penulis melakukan pelatihan algoritma dengan menggunakan parameter yang dianggap memberikan hasil maksimum. Berikut adalah hasil mAP50 berdasarkan parameter optimum:

Tabel 4. 1 Hasil Performansi berdasarkan Parameter Maksimum

Epo ch	train/box _loss	train/cls_ loss	train/df1_ loss	metrics/precisi on(B)	metrics/rec all(B)	metrics/mAP 50(B)
1	0.80594	0.50303	0.97935	0.95128	0.92082	0.98922
2	0.79847	0.49861	0.97999	0.94876	0.92448	0.98908
3	0.81092	0.50205	0.98044	0.94264	0.92809	0.98886
4	0.73454	0.40414	0.93872	0.94495	0.92892	0.98878
5	0.80019	0.49957	0.97829	0.94989	0.92203	0.98864
6	0.77769	0.42895	0.9594	0.95232	0.92421	0.98854
7	0.7354	0.40585	0.94168	0.94464	0.92918	0.98854
8	0.80941	0.50686	0.98352	0.95307	0.91868	0.98852
9	0.75647	0.41643	0.94891	0.94344	0.93042	0.98851
10	0.79732	0.49779	0.9772	0.94893	0.92679	0.98849

Epoch	train/box_loss	train/cls_loss	train/dfl_loss	metrics/precision(B)	metrics/recall(B)	metrics/mAP50(B)
11	0.76684	0.42206	0.95167	0.94865	0.92629	0.98845
12	0.86023	0.53762	0.99937	0.94859	0.92097	0.98842
13	0.72895	0.40284	0.93865	0.94505	0.92986	0.9884
14	0.74673	0.41321	0.94568	0.9407	0.93235	0.98827
15	0.76409	0.41798	0.95266	0.94497	0.92821	0.98825
16	0.73629	0.40678	0.93997	0.94066	0.93246	0.98822
17	0.85432	0.53744	0.99873	0.94557	0.92375	0.98821
18	0.83517	0.52099	0.989	0.94513	0.92735	0.9881
19	0.81599	0.50928	0.98484	0.94594	0.92497	0.98804
20	0.74614	0.40996	0.94432	0.94252	0.93121	0.98782

Sumber: Penulis, 2023

Dari hasil pengujian, dapat dilihat bahwa algoritma yang dibangun dapat mendeteksi objek baut, mur, dan sekrup dengan baik. Hal tersebut ditunjukkan melalui nilai mAP50 yang lebih dari 0.98 atau dalam hal ini, memiliki performansi lebih baik dari eksperimen 1 yang memiliki *S/N Ratio* tertinggi diantara serangkaian parameter yang sudah diuji.

KARAWANG