

Deteksi Cacat pada Sekrup Berbasis Citra Menggunakan YOLOv5

Yoga Panji Perdana Nugraha dan Eri Prasetyo Wibowo

¹Teknik Industri dan Manajemen, Universitas Gunadarma

²Ilmu Komputer dan Teknologi Informasi, Universitas Gunadarma

Jl. Margonda Raya No. 100, Depok 16424, Jawa Barat

E-mail: yogapanji50@gmail.com, eri@staff.gunadarma.ac.id

Abstrak

Perusahaan pasti menginginkan produk yang dihasilkannya berkualitas baik. Kenyataannya kecacatan produk merupakan hal yang sulit dihindari. Kegiatan pengendalian kualitas diperlukan untuk mencegah produk cacat sampai kepada pelanggan. Pengendalian kualitas yang dilakukan manual membutuhkan waktu yang lama dengan tingkat subjektifitas serta resiko *human error* yang tinggi. Pemanfaatan teknologi dibutuhkan untuk membantu kegiatan pengendalian kualitas. Teknologi yang dapat dimanfaatkan untuk pengendalian kualitas adalah *Artificial Intelligence* (AI) dengan metode *deep learning* menggunakan arsitektur YOLOv5. Tujuan penelitian ini adalah mengembangkan model yang dapat mendeteksi kualitas sekrup berbasis citra. Pengolahan data dilakukan dengan *Roboflow* untuk proses *preprocessing*. Proses pembuatan model menggunakan *Google Colab* dengan bahasa pemrograman *python*. Hasil penelitian menunjukkan pelatihan mendapatkan waktu pelatihan sebesar 0.404 jam atau 24.24 menit, precision 0.842, recall 0.857, dan *mean average precision* 0.887. Uji coba yang dilakukan menghasilkan bahwa citra dapat terdeteksi dengan baik. Namun, terdapat beberapa citra yang kurang baik dan maksimal untuk dideteksi.

Kata kunci : Sekrup, Deteksi Objek, *Artificial Intelligence*, *Deep Learning*, YOLOv5

Pendahuluan

Teknik rekayasa dan manufaktur memerlukan pengendalian kualitas untuk menjaga kualitas barang yang diproduksi. Hasil produksi dari teknik rekayasa dan manufaktur salah satunya adalah sekrup. Perusahaan pastinya selalu menginginkan produk yang dihasilkannya berkualitas sangat baik. Kenyataannya cacat produk merupakan sesuatu yang sulit untuk dihindari. Pengendalian kualitas diperlukan untuk menjaga kualitas dari produk yang dihasilkan. Kegiatan pengendalian kualitas produk memiliki departemen sendiri yaitu departemen pengendalian kualitas pada perusahaan yang bertugas untuk mengendalikan dan menjamin kualitas dari produk yang dihasilkan. Muncul masalah dimana pengendalian kualitas yang dilakukan masih secara manual. Hal ini membuat proses pengendalian kualitas membutuhkan waktu yang lebih lama dengan tingkat subjektifitas yang tinggi karena persepsi dari masing-masing operator pengendali kualitas. Kemajuan teknologi saat ini membuat teknik deteksi objek dapat digunakan untuk meningkatkan kinerja pengendalian kualitas. Penelitian ini bertujuan untuk mengem-

bangkan model yang dapat mendeteksi kualitas sekrup berbasis citra yang diunggah. Pengendalian kualitas sekrup merupakan salah satu kegiatan yang dapat diimplemenasikan dengan *Artificial Intelligence* (AI). Teknik deteksi objek yang dapat diimplementasikan yaitu *Artificial Intelligence* (AI) dengan metode *deep learning*. Penelitian ini, pengendalian kualitas dilakukan dengan mendeteksi cacat pada sekrup melalui penglihatan komputer (*computer vision*) menggunakan metode *deep learning* dengan arsitektur YOLOv5. YOLO merupakan jaringan yang digunakan untuk mendeteksi objek sedangkan YOLOv5 adalah metode versi terbaru yang dikembangkan metode YOLO yang berfungsi mendeteksi objek untuk menentukan tempat pada sebuah gambar atau citra pada objek yang hadir dan mengklasifikasikan jenis objeknya [1]. Metode *deep learning* dengan arsitektur YOLOv5 dipilih karena data *input* yang berupa citra memiliki jumlah yang tidak terlalu banyak. Selain itu, algoritma ini dipilih karena memiliki kelebihan berupa kecepatan deteksi tercepat mencapai 140 *frame*/detik. Ukuran file bobot model jaringan deteksi target YOLOv5 juga kecil, hampir 90% lebih kecil dari YOLOv4 [2]. Sehingga proses deteksi gambar da-

pat dilakukan secara efisien.

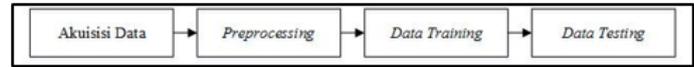
Penelitian untuk meningkatkan kegiatan pengendalian kualitas dalam penerimaan material daur ulang dalam pabrik kaca untuk memeriksa kondisi spesifikasi kebutuhan serta mengurangi keberadaan bahan yang kritis pada bahan baku [3]. Selain itu, usulam kerangka pemodelan pengganti untuk meningkatkan morfologi jalur cetak *inkjet* yang dibuat oleh deposisi mikrotetes berurutan pada substrat tidak berpori. [4]

FE-YOLOv5 yang sederhana namun efektif digunakan untuk merancang *feature enhancement module* (FEM) yang digunakan menangkap fitur yang lebih diskriminatif dari objek kecil serta *spatially aware module* (SAM) untuk menyaring informasi spasial dan meningkatkan ketahanan fitur [5]. Kemudian dibangun juga metode deteksi objek secara otomatis untuk mengidentifikasi pohon dan mengklasifikasikannya berdasarkan kerusakan akibat salju menggunakan arsitektur YOLO CNN [6]. Sistem inspeksi cacat pada permukaan kayu dengan model deteksi objek YOLOv5 [2]. Penelitian serupa juga dilakukan oleh dengan menggunakan berbagai macam metode antara lain integrasi antara YOLOv5 dan ResNet [7], *deep learning* [8, 9], integrasi antara *machine learning* dan *deep learning* [10], FE-YOLOv5 [11], serta YOLOv3 [12]. Selain itu, Aplikasi untuk mendeteksi kualitas daging dikembangkan dengan mengaplikasikan *region of interest* (ROI) [13]. Peningkatan algoritma deteksi dan klasifikasi kendaraan juga coba dibangun menggunakan *Region of Interest* (ROI) [14].

Penelitian yang telah dilakukan sebelumnya dapat diketahui bahwa pengendalian kualitas merupakan kegiatan yang penting untuk menjaga konsistensi kualitas produk agar tetap baik. Pengendalian kualitas yang dilakukan secara konvensional memiliki berbagai macam kendala. Kendala tersebut antara lain membutuhkan waktu yang lama, membutuhkan operator yang banyak dan ahli di bidangnya, tingkat subjektifitas yang tinggi karena persepsi dari masing-masing operator serta resiko *human error* yang tinggi. Peningkatan kinerja pengendalian kualitas pada perusahaan diperlukan salah satu caranya dengan memanfaatkan teknologi. Penelitian ini dilakukan dengan memanfaatkan teknologi untuk mengembangkan model pendeteksi objek cacat pada produk sekrap menggunakan *artificial intelligence* (AI) dengan metode *deep learning* menggunakan algoritma YOLOv5 dimana *dataset* sebelum dilatih dilakukan anotasi terlebih dahulu untuk menentukan *region of interest* (ROI) serta augmentasi untuk memperbanyak data sehingga pelatihan model dan model yang dikembangkan dapat lebih efektif dan efisien. Model dibuat pada *google colab* dengan bahasa pemrograman *python*.

Metode Penelitian

Penelitian ini bertujuan untuk mengembangkan model yang dapat mendeteksi kualitas sekrap berbasis citra yang diunggah. Keluaran yang ditampilkan akan berupa informasi kualitas sekrap tersebut. Berikut ini adalah diagram alir deteksi objek sekrap.



Gambar 1: Diagram Alir Deteksi Objek Sekrap

Gambar 1 merupakan diagram alir dalam deteksi objek pada sekrap. Berikut ini adalah penjelasan dari masing-masing tahapan.

1. Akuisisi Data

Data terbagi menjadi data primer dan data sekunder. Data primer didapatkan dari foto secara langsung menggunakan *handphone* beberapa sekrap untuk pengujian. Data sekunder didapatkan dari *website kaggle* untuk pelatihan.

2. Preprocessing

Roboflow digunakan untuk membantu proses *preprocessing* [16]. Citra sekrap dianotasi menggunakan bounding box untuk memisahkan tiap-tiap kelas serta menentukan *region of interest* (ROI) kemudian dilakukan *resize*, augmentasi dan *generate* sehingga data menjadi suatu *dataset*.

3. Data Training

Data training yang digunakan sebanyak 96% data dari masing-masing kondisi sekrap. Tahap ini melatih model dengan menggunakan algoritma YOLOv5 dengan bahasa pemrograman *python*. Tahap ini juga menghasilkan lama waktu pelatihan serta matriks evaluasi berupa *precision*, *recall*, dan *mean average precision* (MAP).

4. Data Testing

Tahap ini menguji model dengan cara *input* data secara acak yang tidak termasuk ke dalam data *training*. Keluaran dari hasil pengujian ini adalah citra sekrap yang sudah terdeteksi kondisinya apakah OK atau terdapat *defect* pada bagian tertentu.

Hasil dan Pembahasan

Penelitian ini menggunakan *deep learning* dengan algoritma YOLOv5. Algoritma YOLOv5 digunakan untuk mendeteksi objek cacat pada sekrap berbasis citra yang diunggah ke dalam model. Cacat pada sekrap yang akan dideteksi dibagi menjadi 2 kelas yaitu “*Screw-OK*” dan “*Screw-Defect*”.

Berikut ini adalah hasil pengolahan data yang dilakukan.

1. Akuisisi Data

Data yang digunakan terdiri dari data primer dan data sekunder seperti yang sudah dijelaskan sebelumnya. Data-data tersebut berisi citra sekrup dengan berbagai macam kondisi. Terdapat 4 kelas yaitu OK, *manipulated*, *scratch*, dan *thread*. Jumlah pada beberapa kelas yang terbatas sehingga beberapa kelas disatukan sehingga hanya menjadi 2 kelas yaitu OK dan *Defect*. Berikut ini merupakan contoh data citra *screw* yang digunakan.

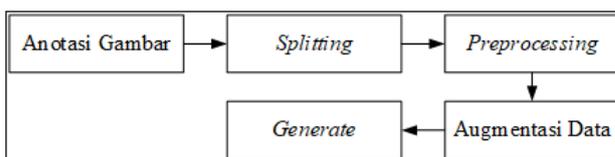


Gambar 2: Contoh Citra Sekrup [15]

Gambar 2 adalah contoh citra sekrup yang didapat dari *website kaggle* [15]. Data yang berhasil diakuisisi selanjutnya dilakukan *pre-processing* untuk menyiapkan data sebelum dilatih pada model.

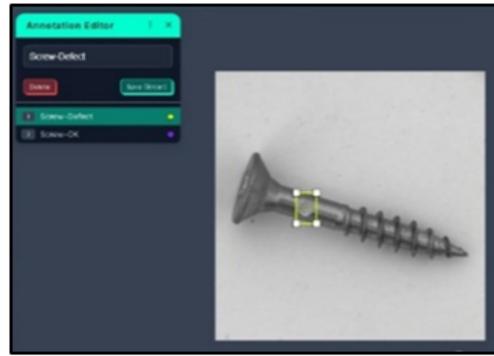
2. Preprocessing

Preprocessing dilakukan dengan menggunakan *roboflow*. Berikut ini adalah tahapan *preprocessing* pada *robflow*.



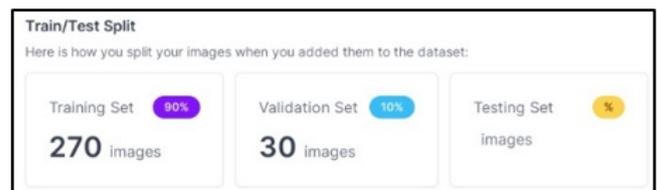
Gambar 3: Tahapan pada *Roboflow*

Gambar 3 merupakan tahapan pada *robflow*. Pertama adalah Anotasi Gambar, dimana menganotasi gambar menggunakan fitur *rectangle* lalu membuat *bounding box* pada area yang ingin di anotasi.



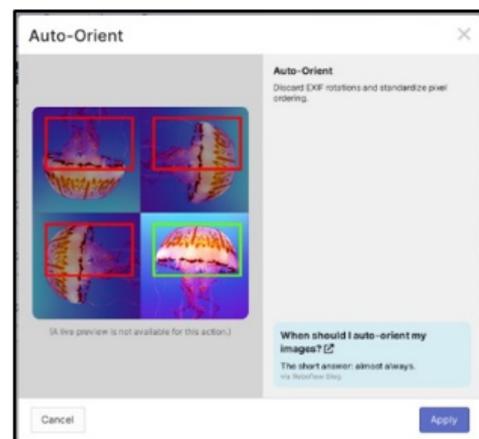
Gambar 4: Anotasi Gambar pada *Roboflow*

Gambar 4 merupakan contoh anotasi gambar pada *robflow*. Area yang dianotasi adalah area yang dianggap penting (*Region of Interest*). Proses ini juga akan memisahkannya ke dalam kelas masing-masing. Berikut ini merupakan proses anotasi gambar pada *robflow*. Kedua adalah *splitting*, tahap ini dilakukan untuk membagi data menjadi data data latih (*train*) dan data validasi (*valid*).



Gambar 5: *Splitting*

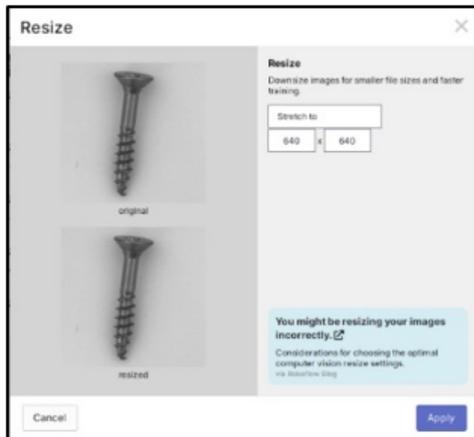
Gambar 5 *splitting* untuk membagi data. Persentase yang digunakan adalah 90% untuk data latih dan 10% untuk data validasi. Data yang sudah terbagi menjadi data latih dan data *valid* selanjutnya akan masuk pada tahap *Preprocessing*.



Gambar 6: *Auto-Orient*

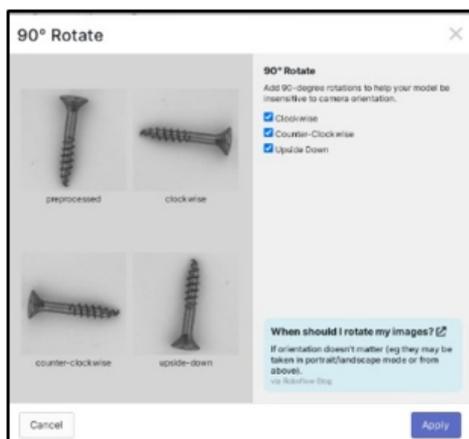
Gambar 6 menunjukkan pengaplikasian *auto-orient*. Tahap ini dilakukan untuk meny-

makan orientasi data. Tahap selanjutnya adalah mengaplikasikan *resize*.



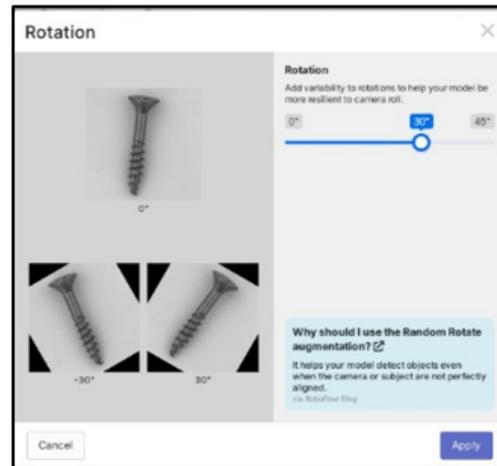
Gambar 7: *Resize*

Gambar 7 menunjukkan *resize* menjadi 640x640 untuk mengoptimalkan kecepatan pelatihan data. *Auto-orient* dan *resize* pada bagian *preprocessing* telah diaplikasikan maka tahap selanjutnya adalah augmentasi data. Augmentasi data dilakukan untuk memperbanyak data secara otomatis dengan berbagai macam kondisi yang diinginkan. Augmentasi data yang pertama adalah mengaplikasikan 90° *Rotate* dengan arah *Clockwise*, *Counter-Clockwise*, *Upside Down*. Berikut ini adalah pengaplikasian 90° *Rotate* pada *roboflow*.



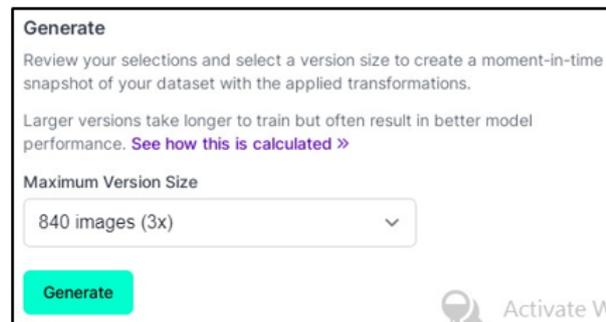
Gambar 8: *90° Rotate*

Gambar 8 menunjukkan pengaplikasian 90o *Rotate* untuk membuat data citra berotasi sebesar 90°. *Rotation* juga diaplikasikan pada data. Perbedaan *rotation* dengan 90° *rotate* adalah pada *rotation* dapat diatur sudut kemiringan rotasi pada gambar.



Gambar 9: *Rotation*

Gambar 9 menunjukkan pengaplikasian *rotation*. Sudut kemiringan yang digunakan adalah +30° dan -30°. Augmentasi data telah dilakukan maka didapatkan maximum *version size* sebanyak 840 *images*. Hal ini dikarenakan terdapat data yang ditambahkan secara otom

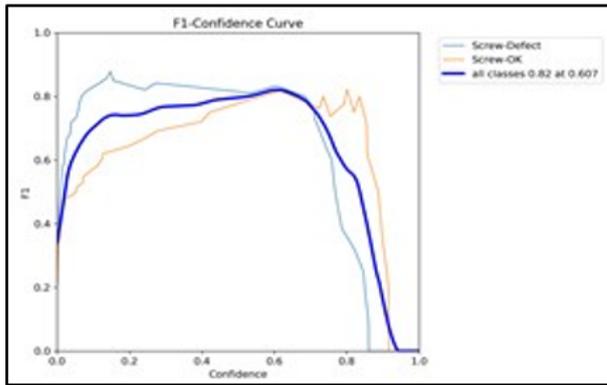


Gambar 10: *Generate*

Gambar 10 merupakan tahap *generate*. Tahap ini dilakukan agar *dataset* terinput ke dalam satu versi yang siap untuk dilatih menggunakan model yang akan dibangun. Berikut ini adalah *generate* data pada *roboflow*.

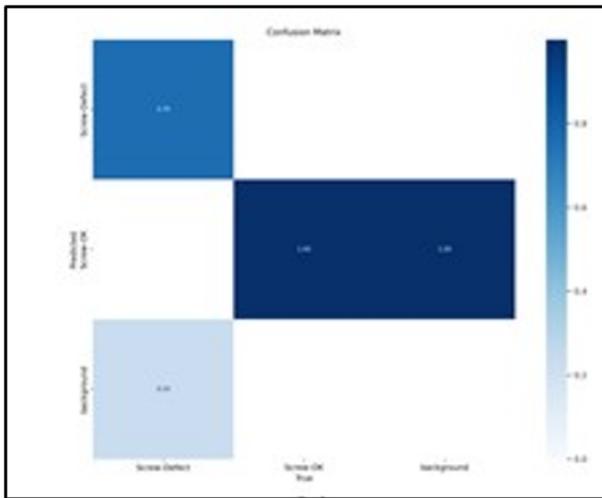
3. *Data Training*

Pelatihan data dilakukan dengan membuat program pada *google colab* dengan *python*. Pelatihan dilakukan dengan menggunakan algoritma YOLOv5 berbasis data citra yang diunggah. Pelatihan model ini menggunakan *epochs* sebesar 150 *epochs* dengan *patience* yaitu 20 *epochs*. Artinya pengulangan pelatihan dilakukan sebanyak 150 kali dimaana jika selama 20 *epochs* terakhir tidak terdapat peningkatan kinerja yang signifikan maka pelatihan akan berhenti lebih cepat walaupun belum mencapai 150 *epochs* (*Early Stopping*). Berikut ini merupakan hasil pelatihan data.



Gambar 11: *F-1 Confidence Curve*

Gambar 11 Kurva *F-1 Confidence* diketahui nilai F-1 dari model yang dilatih adalah 0.82 atau 82%, angka tersebut menunjukkan kualitas yang baik pada model dalam menyeimbangkan *precision* dan *recall*. Nilai *confidence* 0,607 artinya model hanya mempertimbangkan deteksi yang memiliki kepercayaan setidaknya 0,607. Kesimpulannya adalah model hanya mengambil hasil deteksi yang memiliki tingkat kepercayaan relatif tinggi.



Gambar 12: *Confusion Matrix Pelatihan dengan Google Colab*

Gambar 12 *Confusion matrix* diketahui untuk kelas 'Screw-Defect' yang terdeteksi 'Screw-Defect' (*True Positive*) adalah 0.76 atau 76% sedangkan untuk kelas 'Screw-OK' yang terdeteksi 'Screw-OK' (*True Negative*) adalah 1.00 atau 100%. Kelas 'Screw-Defect' namun terdeteksi *background* sebesar 0.24 atau 24%. *Background* yang terdeteksi kelas 'Screw-OK' sebesar 1.00 atau 100%. Hal ini menandakan bahwa model yang mendeteksi *background* terdeteksi sebagai kelas 'Screw-OK' seluruhnya. Pengukuran evaluasi juga dijelaskan pada penelitian ini. Pengukuran

evaluasi yaitu *precision*, *recall*, dan *mean average precision* (MAP). Berikut ini adalah tabel pengukuran evaluasi.

Tabel 1: Pengukuran Evaluasi Pelatihan

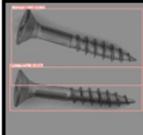
Waktu Pelatihan	<i>Precision</i>	<i>Recall</i>	MAP
0,404 jam / 24,24 menit	0,842	0,857	0,887

Tabel 1 pengukuran evaluasi pelatihan menunjukkan bahwa waktu pelatihan model menggunakan *google colab* menghabiskan waktu 0,404 jam atau 24,24 menit. *Precision* yang didapatkan yaitu 0,842 yang artinya 84,2% dapat dideteksi secara *positive* sedangkan sisanya adalah *false positive*. *Recall* yang didapatkan adalah 0,857 artinya model mampu mengenali 85,7% dari objek positif, hal ini menandakan bahwa model relatif baik. *Mean average precision* (MAP) yang digunakan adalah MAP_{0,5} atau MAP pada *Intersection Over Union* (IoU) 0,50. Nilai MAP_{0,50} sebesar 0,887 artinya model memiliki kemampuan yang baik dalam mendeteksi objek. Data yang tidak terlalu banyak namun menghasilkan waktu pelatihan 0,404 jam atau 24,24 menit mengindikasikan bahwa waktu pelatihan yang dibutuhkan cukup lama. Hal ini akan sangat berpengaruh pada proses pelatihan jika nantinya data yang digunakan lebih banyak dan variatif.

4. Data Testing

Data Testing dilakukan untuk menguji model dengan mendeteksi objek menggunakan data citra *screw* atau sekrup yang tidak digunakan dalam pelatihan. Tahap ini dilakukan untuk mengetahui sejauh mana model dapat mendeteksi objek cacat pada *screw* sehingga dapat digunakan untuk kegiatan pengendalian kualitas pada perusahaan. Pengujian data dilakukan dengan mengunggah data citra sekrup yang tidak digunakan dalam pelatihan. Berikut ini adalah hasil dari pengujian model untuk mendeteksi objek cacat pada sekrup.

Tabel 2: Hasil Deteksi Objek Sekrup dengan *Google Colab*

Hasil Deteksi Objek	Confidence Score
	0.70 dan 0.25
	0.80
	0.75
	0.58 dan 0.6
	0.58
Hasil Deteksi Objek	Confidence Score
	0.64 dan 0.33
	0.79
	0.80 dan 0.63
	0.41, 0.48, 0.26 dan 0.75.

Tabel 2 hasil deteksi objek sekrup dengan *google colab* menunjukkan hasil pendeteksian objek sekrup oleh model dengan menampilkan gambar disertai *bounding box* serta nilai *confidence*. Contohnya pada gambar pertama, terdapat gambar sekrup yang terdapat *bounding box* pada bagian ujungnya yang menandakan bahwa terdapat cacat pada bagian tersebut dengan nilai *confidence* dari model yang dibuat adalah 0.70 dan 0.25. Hal tersebut juga berlaku pada gambar-gambar berikutnya. Gambar berikutnya merupakan sekrup dengan *bounding box* pada bagian tertentu serta nilai *confidence* dari masing-masing gambar sebagai hasil dari pendeteksian objek sekrup menggunakan YOLOv5 pada *google colab*.

Penutup

Penelitian yang telah dilakukan menunjukkan bahwa model dapat berjalan dengan baik dan dapat menampilkan *output* yang diinginkan yaitu berhasil mendeteksi objek *screw* sesuai kualitasnya dengan membaginya menjadi kelas *Screw-Defect* dan *Screw-OK* berdasarkan citra *screw* yang diunggah. Tujuan dari penelitian ini sudah terpenuhi yaitu mengembangkan model yang dapat mendeteksi kualitas *screw* berbasis citra yang diunggah. Model dapat menampilkan *output* berupa informasi kualitas *screw* tersebut sesuai dengan kelasnya. Proses pelatihan data mendapatkan waktu pelatihan sebesar 0.404 jam atau 24.24 menit, nilai *precision* sebesar 0.842, *recall* sebesar 0.857, dan *mean average precision* (MAP) sebesar 0.887. Pengujian data dilakukan dengan mengunggah beberapa citra *screw* dengan *single object* dan *multiple object*. Uji coba yang dilakukan menghasilkan bahwa citra dapat terdeteksi dengan baik. Namun, terdapat beberapa citra yang kurang baik dan maksimal untuk dideteksi. Hal ini dikarenakan kompleksitas dan variasi serta jumlah dari data pelatihan yang digunakan kurang kompleks dan variatif serta jumlah yang sedikit. Citra yang digunakan untuk menguji model memiliki beberapa kondisi tertentu belum mampu dideteksi dengan maksimal oleh model. Penelitian ini menghasilkan model pendeteksi objek dengan hasil deteksi yang baik namun tidak menutup kemungkinan dapat ditingkatkan kembali agar lebih baik dari segi *dataset* maupun akurasi pendeteksian objek.

Penelitian selanjutnya diharapkan dapat meningkatkan kinerja model terutama waktu pelatihan. Penelitian selanjutnya jika menggunakan data yang lebih banyak dan variatif maka proses pelatihan dapat dilakukan dengan lebih cepat dan efisien.

Daftar Pustaka

- [1] D. I. Mulyana, M. F. Lazuardi dan M. B. Yel, "Deteksi Bahasa Isyarat Dalam Pengenalan Huruf Hijaiyah Dengan Metode YOLOv5", *Jurnal Teknik Elektro dan Komputasi*, vol. 4, no. 2, pp. 145-151, doi.org/10.32528/elkom.v4i2.8145, 2022.
- [2] F. Akhyar, L. Novamizanti dan T. Riantiarni, "Sistem Inspeksi Cacat pada Permukaan Kayu menggunakan Model Deteksi Obyek YOLOv5", *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, Teknik Elektronika*, vol. 10, no. 4, p. 990, doi.org/10.26760/elkomika.v10i4.990, 2022.
- [3] J. Asín, M. Ávila-de la Torre, L. Berges-Muro and B. , Sánchez-Valverde, "Improvement of the Quality Control Plan in the reception of

- waste glass. Application in Verallia", *Procedia Manufacturing*, vol. 13, pp. 1135-1142, doi.org/10.1016/j.promfg.2017.09.175, 2017.
- [4] J. F. Reyes-Luna, S. Chang, C. Tuck and I. Ashcroft, "A surrogate modelling strategy to improve the surface morphology quality of inkjet printing applications", *Journal of Manufacturing Processes*, vol. 89, pp. 458-471, doi.org/10.1016/j.jmapro.2023.01.078, 2023.
- [5] M. Wang et al., "FE-YOLOv5: Feature enhancement network based on YOLOv5 for small object detection", *Journal of Visual Communication Image Representation*, vol. 90, p. 103752, doi.org/10.1016/j.jvcir.2023.103752, 2023.
- [6] S. Puliti and R. Astrup, "Automatic detection of snow breakage at single tree level using YOLOv5 applied to UAV imagery", *International Journal of Applied Earth Observation Geoinformation*, vol. 112, p. 102946, doi.org/10.1016/j.jag.2022.102946, 2022.
- [7] O. Jarkas et al., "ResNet and Yolov5-enabled non-invasive meat identification for high-accuracy box label verification", *Engineering Applications of Artificial Intelligence*, vol. 125, p. 106679, doi.org/10.1016/j.engappai.2023.106679, 2023.
- [8] N. H. Tasnim, S. Afrin, B. Biswas, A. A. Anye and R. Khan, "Automatic classification of textile visual pollutants using deep learning networks", *Alexandria Engineering Journal*, vol. 62, pp. 391-402, doi.org/10.1016/j.aej.2022.07.039, 2023.
- [9] R. Essah, D. Anand and S. Singh, "An intelligent cocoa quality testing framework based on deep learning techniques", *Measurement: Sensors*, vol. 24, p. 100466, doi.org/10.1016/j.measen.2022.100466, 2022.
- [10] M. Ficzer et al., "Real-time coating thickness measurement and defect recognition of film coated tablets with machine vision and deep learning", *International Journal of Pharmaceutics*, vol. 623, p. 121957, doi.org/10.1016/j.ijpharm.2022.121957, 2022.
- [11] Y. Shi et al., "A review on meat quality evaluation methods based on non-destructive computer vision and artificial intelligence technologies", *Food science of animal resources*, vol. 41, no. 4, p. 563, doi.org/10.5851/2Fkosfa.2021.e25, 2021.
- [12] J. Redmon and A. Farhadi, "Yolov3: An incremental improvement", *arXiv preprint arXiv:02767*, doi.org/10.48550/arXiv.1804.02767, 2018.
- [13] R. F. Falah, O. D. Nurhayati dan K. T. Martono, "Aplikasi pendeteksi kualitas daging menggunakan segmentasi region of interest berbasis mobile", *Jurnal Teknologi dan Sistem Komputer*, vol. 4, no. 2, pp. 333-343, doi.org/10.14710/jtsiskom.2016.12720, 2016.
- [14] A. H. Pratomo, W. Kaswidjanti, and S. Mu'arifah, "Implementasi algoritma region of interest (ROI) untuk meningkatkan performa algoritma deteksi dan klasifikasi kendaraan", *J. Teknol. Inf. dan Ilmu Komputer*, vol. 7, no. 1, pp. 155-162, 2020.
- [15] Rarirure Ruru, "Screw Dataset", *Kaggle*, diakses daring pada: <https://www.kaggle.com/datasets/ruruamour/screw-dataset/data>, 2023.
- [16] Anonim, "Object Detection Screw Dataset", *Roboflow Gunadarma University*, diakses daring pada: <https://universe.roboflow.com/gunadarma-university-oo4uc/object-detection-screw>, 2023

Halaman ini sengaja dikosongkan.