

Identifikasi Kerusakan Badan Kontainer Pada Waktu Pengiriman Berdasarkan Citra CCTV Memanfaatkan YOLO dan Deep Transfer Learning

Fitra Hidayah^{1*}, Yosi Kristian²

^{1,2} Program Studi Teknologi Informasi, Institut Sains dan Teknologi Terpadu Surabaya, Jawa Timur
Email: ^{1*}fitra_h20@mhs.istts.ac.id, ²yosi@stts.edu

(Naskah masuk: 23 Nov 2023, direvisi: 7 Des 2023, diterima: 3 Jan 2024)

Abstrak

Keamanan dalam operasional pelabuhan sangat ditentukan oleh kemampuan untuk mengawasi dan melindungi kontainer, yang meskipun berperan sebagai sarana utama perlindungan, masih rentan terhadap kerusakan. Rekaman CCTV di pelabuhan tidak dapat mengenali jenis kendaraan, seperti membedakan antara truk yang membawa kontainer dan yang tidak, serta tidak mampu mendeteksi kerusakan pada kontainer secara otomatis. Dalam mengatasi masalah ini, studi ini mengembangkan sebuah sistem untuk mendeteksi kontainer dan mengklasifikasikan jenis-jenis kerusakan seperti kerusakan struktural, korosi, depos, cacat pada cat, pembengkakan, serta masalah pada pintu kontainer, dengan memanfaatkan teknik *machine learning*. Menggunakan pendekatan *Convolutional Neural Network* (CNN) yang ditingkatkan dengan metode *transfer learning* dari *Deep Convolutional Neural Network* (DCNN), penelitian ini memberikan solusi analitis untuk citra yang diperoleh. *Dataset* yang terdiri dari 3000 gambar kontainer sisi depan dan belakang dikategorikan secara manual melalui *platform* Roboflow. Model YOLOv7 yang terlatih pada *dataset* tersebut mampu mendeteksi kontainer dengan Skor F1 Terboboti mencapai 90%. Untuk tahap klasifikasi kerusakan kontainer, citra yang telah di-*crop* berdasarkan output YOLOv7 dianalisis kembali menggunakan model *EfficientNetV2S* dan *ConvNeXtBase*. Kedua model tersebut, dengan pemanfaatan *transfer learning*, menunjukkan performa yang dengan *Weighted Average F1 Score* berturut-turut sebesar 66% dan 72%. Penelitian ini membuka jalur baru untuk peningkatan keamanan dan pemeliharaan kontainer melalui penerapan model pengenalan gambar yang inovatif di lingkungan pelabuhan.

Kata Kunci: Convolution Neural Network, EfficientNetV2S, ConvNeXtBase, YOLO v7, Klasifikasi Badan Kontainer.

Identification of Container Body Damage During Delivery Based on CCTV Images Using YOLO and Deep Transfer Learning

Abstract

The security of port operations is heavily dependent on the ability to monitor and protect containers, which, despite serving as the primary means of protection, remain vulnerable to damage. CCTV recordings at the port are unable to recognize vehicle types, such as distinguishing between container-carrying trucks and those that are not, and cannot automatically detect damage to containers. To address this issue, this study developed a system to detect containers and classify various types of damage, including structural damage, corrosion, deposits, paint defects, bulges, and container door issues, using machine learning techniques. Leveraging an improved Convolutional Neural Network (CNN) approach with transfer learning from the Deep Convolutional Neural Network (DCNN), this research provides an analytical solution for the acquired images. A dataset consisting of 3000 front and rear container images was manually categorized using the Roboflow platform. The YOLOv7 model trained on this dataset was capable of detecting containers with a Weighted F1 Score of 90%. For the container damage classification stage, images cropped based on the YOLOv7 output were reanalyzed using the EfficientNetV2S and ConvNeXtBase models. Both of these models, utilizing transfer learning, exhibited satisfactory performance with consecutive Weighted Average F1 Scores of 66% and 72%. This research paves the way for enhancing container security and maintenance through the implementation of innovative image recognition models in the port environment.

Keywords: Deep Convolution Neural Network, EfficientNetV2S, ConvNeXtBase, YOLO v7, Container Body Classification.

I. PENDAHULUAN

Indonesia, sebagai negara berkembang yang terdiri dari berbagai pulau-pulau, terletak di tengah lautan yang memisahkan berbagai wilayahnya. Keberadaan berbagai pelabuhan, mulai dari yang berskala kecil hingga internasional, menjadi kunci dalam menjalankan hubungan dan konektivitas antar pulau. Pelabuhan-pelabuhan ini memainkan peran penting dalam menghubungkan transaksi dengan negara-negara lain di seluruh dunia, terutama dalam kegiatan ekspor dan impor. Indonesia memiliki peran yang signifikan dalam perdagangan internasional, menjadi salah satu terminal petikemas terbesar di dunia dalam hal penggunaan kontainer sebagai sarana untuk mengangkut barang.

Proses pengiriman barang ekspor dan impor sering kali melibatkan perusahaan pelayaran yang menggunakan kontainer sebagai media utama. Penggunaan kontainer memiliki banyak keunggulan, terutama dalam kapasitas penyimpanan yang lebih besar, dan melindungi barang-barang dari potensi kerusakan [1]. Proses pergerakan kontainer di pelabuhan dalam operasional kegiatan pengiriman dan kedatangan melibatkan berbagai pihak yang memiliki kepentingan, yang berhungan erat oleh jasa Ekpedisi sebagai penyelenggara pengangkutan. Selain itu, terdapat peran penting pelabuhan, termasuk fasilitas muat, transit, dan bongkar, serta depo yang juga berperan dalam menyelenggarakan proses ini [2].

Namun perlu diingat bahwa bahkan kontainer pun rentan terhadap kerusakan. Kerusakan pada kontainer dapat mempengaruhi isi didalam kontainer. Seperti korosi yang menyebabkan perubahan kelembapan yang mempengaruhi dan merusak muatan dari kontainer tersebut.

Penelitian sebelumnya [3], [4] dan [5]. Penelitian ilmiah menganalisis kerusakan kontainer di pelabuhan China dengan metode Fmask Rcn dan Mask Rcn pada 4407 gambar [3]. Penelitian ilmiah menganalisis visual retakan beton dengan metode Fmask FCN dan SegNet pada 550 gambar [4]. Pengumpulan data kerusakan jalan di tujuh kota Jepang menggunakan *smartphone* dengan 9053 gambar dan 15.435 contoh rusak jalan dengan model SSD menggunakan dua pendekatan, Inception V2 dan MobileNet [5].

Berdasarkan penelitian sebelumnya yang menggunakan citra dari kamera, yang sebelumnya hanya berfungsi sebagai alat perekam dengan keterbatasan informasi, dengan teknik machine learning yang telah diterapkan untuk memberikan informasi yang berguna dalam berbagai pekerjaan, seperti deteksi kerusakan jalan, deteksi retakan beton, dan deteksi kerusakan kontainer. Dalam penelitian ini, citra CCTV yang diperoleh dari pelabuhan dimanfaatkan untuk mengidentifikasi objek, khususnya sebagai pemisah antara truk yang membawa kontainer dengan objek lain. Selanjutnya, citra hasil identifikasi digunakan untuk mengklasifikasikan setiap kerusakan yang terdapat pada badan kontainer. selama ini di pelabuhan belum ada alat yg digunakan untuk mendeteksi kerusakan kontainer yg mengakibatkan dilakukan pemeriksaan manual badan

kontainer oleh petugas. Hasil penelitian ini diharapkan dapat meningkatkan kemampuan pengawasan dan keakuratan dalam mengidentifikasi masalah terkait kontainer di lingkungan pelabuhan.

Dalam penelitian ini, peneliti dapat memberikan kontribusi. Pertama, peneliti berfokus pada pembangunan *dataset* untuk model kerusakan kontainer. Selain itu, peneliti melatih *dataset* kontainer yang sebelumnya masih belum tercakup dalam YOLO, sehingga model YOLO dapat mendeteksi kontainer dengan akurasi tinggi dari berbagai sudut, baik depan maupun belakang. Selanjutnya, peneliti mengembangkan metode *deep transfer learning* untuk mendeteksi berbagai jenis kerusakan pada citra badan kontainer. Dengan pendekatan ini, penelitian ini diharapkan dapat meningkatkan kemampuan deteksi dan klasifikasi kerusakan pada kontainer secara efektif.

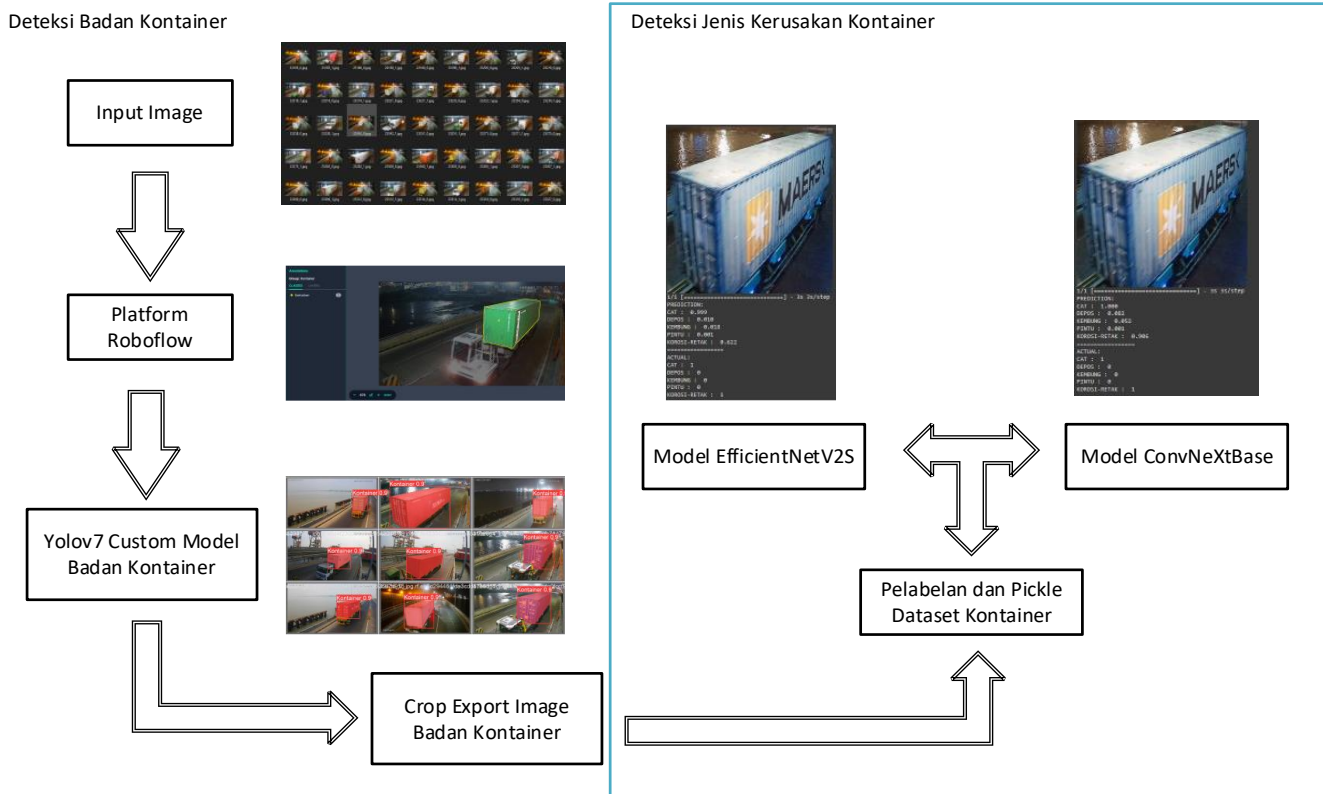
Hal ini merupakan langkah signifikan dalam pengembangan teknologi deteksi kerusakan kontainer yang dapat memiliki dampak positif pada efisiensi dan keamanan dalam kegiatan ekspor dan impor dipelabuhan.

II. TINJAUAN PUSTAKA

Pada paper I, [3] penulis menganalisis Identifikasi Kerusakan Kontainer di salah satu Pelabuhan di China. Penulis menggunakan dua pendekatan, yaitu Fmask Rcn dan Mask Rcn, untuk mengidentifikasi beberapa jenis kerusakan kontainer dengan jumlah data sebanyak 4.407 gambar. Hasil pengujian dengan kedua metode tersebut menghasilkan akurasi parameter sebagai berikut: Fmask Rcn memiliki tingkat kehilangan (*miss*) sebesar 6,4% dan tingkat kesalahan (*error*) sebesar 18,8%, sementara Mask Rcn memiliki tingkat kehilangan sebesar 11,8% dan tingkat kesalahan sebesar 20,2%.

Pada paper II, [4] penulis menganalisis kerusakan atau retakan pada struktur beton secara visual. Penulis menggunakan dua pendekatan, yaitu Fmask FCN dan SegNet, untuk mengidentifikasi retakan pada beton dengan jumlah data sebanyak 550 gambar. Hasil pengujian dengan kedua metode tersebut menghasilkan akurasi parameter sebagai berikut: Untuk Fmask FCN, akurasi mencapai 98,61% dan rata-rata akurasi sebesar 91,59%, sementara untuk SegNet, akurasi mencapai 98,62% dan rata-rata akurasi sebesar 98,16%.

Pada paper III, [5] penulis mengumpulkan data tentang kerusakan jalan di tujuh kota di Jepang. Penulis berhasil mengumpulkan 9.053 gambar menggunakan *smartphone*, yang mencakup 15.435 contoh kerusakan jalan. Tujuan dari riset ini adalah memperoleh sistem tentang kondisi jalan yang rusak secara *real-time* dengan model SSD (*Single Shot MultiBox Detector*). Penulis mengimplementasikan dua pendekatan, yaitu Inception V2 dan MobileNet. Hasil dari penelitian ini menunjukkan bahwa algoritma Inception V2 mencapai tingkat akurasi sebesar 95%, sementara algoritma MobileNet juga mencapai tingkat akurasi yang sama, yaitu 95%.



Gambar 1. Alur Pemrosesan Citra Kontainer

III. METODE PENELITIAN

Jenis *Neural Network* yang sering dan baik untuk klasifikasi gambar dengan memilih menggunakan pendekatan *Convolutional Neural Network* (CNN) yang ditingkatkan dengan metode *transfer learning* dari *Deep Convolutional Neural Network* (DCNN). Tahapan meliputi pengumpulan *dataset*, *platform Roboflow*, YOLO identifikasi badan kontainer, *dataset* pelabelan tahap kedua, *Feature Learning* dan *Classification* dalam penerapan pelatihan pembuatan model CNN untuk jenis kerusakan badan kontainer seperti terlihat pada Gambar 1.

A. Dataset

Dalam penelitian ini, peneliti memilih gambar kontainer dikumpulkan oleh CCTV pelabuhan sebanyak 3.000, gambar yang terdiri tidak ada kerusakan dan gambar kontainer dengan 5 jenis kerusakan yang berbeda. Setelah itu peneliti melakukan pelabelan deteksi badan kontainer menggunakan *platform Roboflow* pada 3.000 gambar, dengan menggunakan *custom YOLOv7* hanya di area kontainer. Setelah langkah tersebut, peneliti melaksanakan proses pelabelan yang sesuai dengan kategori jenis kerusakan. Pembagian *dataset* kontainer pada *data training* 80% yaitu 2.400 gambar dan *training testing* 20% yaitu 600 gambar.

B. Feature Learning

Feature learning proses konversi citra menjadi representasi numerik yang disebut fitur [6]. Proses ini melibatkan beberapa lapisan (*layer*) yang bekerja bersama

untuk menghasilkan representasi gambar:

1) Convolutional Layer

Convolutional Layer pada CNN lapisan ini menggunakan filter untuk mengekstrak fitur seperti tepi, sudut, dan tekstur dari citra.

2) Activation Layer

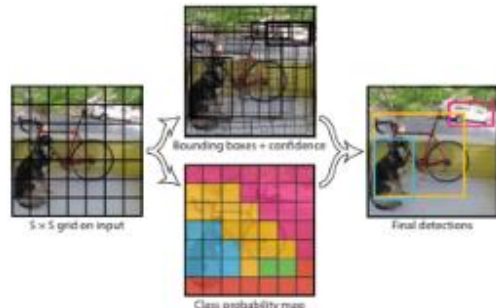
Activation Layer pada CNN berfungsi aktivasi atau memperkenalkan serta menambahkan non-linearitas ke fitur yang diekstrak pada model.

3) Pooling Layer

Pooling layer Lapisan ini mereduksi dimensi spasial dari fitur yang diekstrak, membantu mengurangi beban komputasi dan mencegah *overfitting* [7]. Suatu kondisi adanya peningkatan nilai *loss* dimana model rumit untuk memahami data pelatihan disebut *Overfitting*. Disaitulah perlu seleksi dari beragam *pooling layer* [8].

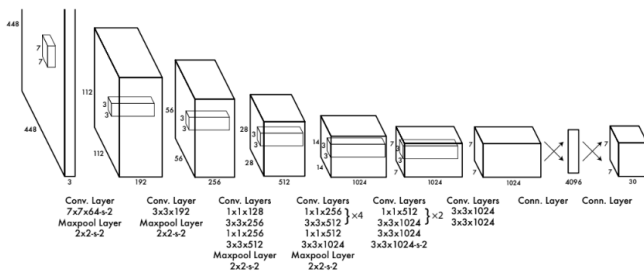
C. Pembuatan YOLO Model

YOLO adalah suatu pendekatan dalam komputer *vision* dan *deep learning* untuk deteksi objek *real-time*. Dalam konteks ini, *You Only Look Once* (YOLO) merujuk pada kemampuan sistem untuk mendeteksi objek dalam satu iterasi melalui jaringan saraf (*neural network*) secara keseluruhan, sehingga membuatnya lebih efisien daripada pendekatan deteksi objek konvensional. YOLO merupakan suatu pengenalan objek yang berbasis CNN (Gambar 2). YOLO pada umumnya digunakan dalam aplikasi pengawasan video akan tetapi YOLO juga dapat digunakan untuk mengeluarkan fitur dari citra.



Gambar 2. Ilustrasi Model YOLO

Peneliti menggunakan YOLOv7 *custom data* karena penambahan efisien *layer* atau *Extended Efficient Layer Aggregation*, konfigurasi keefisienan model atau *Model Scaling Techniques*, memperhalus dan penyesuaian penyusunan *neural network* atau *Re-parameterization Planning Auxiliary Head Coarse-to-Fine* dan lapisan konvolusional jaringan YOLO sangat efisien. YOLOv7 dirancang dengan teknik-teknik ini untuk meningkatkan kinerja dan keakuratan deteksi objek dalam situasi *real-time*, membuatnya menjadi pilihan yang tepat dalam konteks penelitian dengan arsitektur seperti terlihat pada Gambar 3.



Gambar 3. Arsitektur Model YOLO

Pada penelitian ini, peneliti menggunakan YOLOv7 *custom dataset* untuk pengenalan kontainer yang terlihat pada gambar yang tertangkap CCTV dalam mengambil truk yang bermuatan kontainer (Gambar 4). Tahap pertama *preprocessing* melakukan pelabelan deteksi badan kontainer menggunakan *platform* Roboflow pada 3.000 gambar. Dilanjutkan *training* YOLO *custom dataset* citra kontainer terdapat *wrapping* atau *bouding box* merupakan proses pembungkusan tujuan dari pendeteksian badan kontainer dan *cropping* merupakan proses pemisahan atau penghapusan tepi dari *wrapping* yang berguna dalam meningkatkan rasio dan berisi dari citra [6].



Gambar 4. Prediksi *Data Testing*

Peneliti mendapatkan nilai skor F1 terboboti mencapai 90%, dengan nilai untuk model *custom data* YOLOv7 dari citra CCTV pada *dataset* badan kontainer.

D. *Classification*

Tujuan *classification* untuk setiap ekstrak *neuron* dikelompokkan ke dalam kelas serta kategori yang dimana lapisan ini saling berkaitan dan dalam proses *classification* ada beberapa fungsi.

1) *Flatten*

Flatten merupakan pembentukan ulang *feature map* (*reshape*) yang berfungsi sebagai masukan *fully-connected layer*.

2) *Fully-Connected Layer*

Fully Connected Layer merupakan lapisan-lapisan yang telah terhubung yang digunakan untuk menggabungkan fitur-fitur yang diekstraksi dan membuat prediksi akhir.

E. Pemrosesan Hasil Model YOLO

Pemilihan dan pengelompokan dalam pengumpulan citra badan kontainer ini hasil keluaran pengolahan model YOLO *custom dataset* dengan kriteria:

- 1) Badan kontainer normal tanpa kerusakan.
- 2) Badan kontainer dengan lima jenis kerusakan seperti cat, depos, kembang, kerusakan pintu, korosi retakan.
- 3) Badan kontainer tampak depan atau tampak belakang.
- 4) Badan kontainer berwarna disimpan dalam bentuk JPG, berukuran 384 x 384.

Selanjutnya citra kontainer diproses pelabelan sesuai jenis kerusakan. Kemudian untuk porses *training* dan pembuatan model *deep transfer learning* citra disimpan pada proses *pickle* sebagai representasi biner dari citra badan kontainer.

F. Pembuatan Model *Deep transfer learning*

Setelah hasil YOLO mendeteksi badan kontainer dilanjutkan pelabelan dan penyimpanan representasi biner dalam proses *pickle*. Untuk kerangka yang kuat peneliti menggunakan *framework Keras Applications* dalam percepatan pembelajaran *neural network* yang optimal dan *Tensorflow* sebagai backend dari *keras* dalam implementasi model [9], [10]. Karena tujuan dan target penelitian tidak dimulai dari awal maka *Transfer learning* dapat meningkatkan akurasi serta efisiensi model yang dihasilkan [11], [12]. *ConvNeXtBase* Dan *EfficientNet* merupakan jenis *Convolutional neural network* (CNN) yang telah dioptimalkan kecepatan latihan, penyesuaian parameter yang tepat guna dari model sebelumnya [13].

G. *Training*

Dalam klasifikasi kerusakan kontainer penggunaan dan pengembangan *neural network* proses *feedforward* atau proses data *input* didalam *neuron* yang saling terhubung tanpa penyesuaian parameter dan *backpropagation* atau proses optimasi dalam mengurai kesalahan merupakan kombinasi tahapan penting dalam *Training*. Tujuan dari *training* ini membandingkan hasil akurasi model *EfficientNetV2S* dan *ConvNeXtBase*. Proses ini menggunakan 3.000 data citra kontainer dengan *epoch* 20, *batchsize* 100.

H. Confusion Matrix

Dalam meninjau performa nilai aktual model metode *Confusion Matrix* dapat diterapkan untuk memberikan hasil evaluasi antaran lain akurasi, *Precision*, *Recall*, *F1 Score*, *Miss Detection* [14].

Accuracy (1) merupakan sebuah metrik untuk mengukur rasio dari semua prediksi yang benar dibandingkan dengan semua prediksi yang dilakukan. Akurasi digunakan untuk melihat seberapa akurat model berdasarkan jumlah dari TP dan TN.

$$Akurasi = \frac{True\ Positive}{Total\ Data} \tag{1}$$

F1-score (2) merupakan sebuah metrik yang digunakan untuk mengevaluasi akurasi dari *testing*. *F1-score* menggabungkan nilai dari presisi dan *recall* dengan menggunakan konsep yaitu *harmonic mean*.

$$F1\ Score = \frac{2 * Precision * Recall}{Precision + Recall} \tag{2}$$

Precision (3) merupakan sebuah metrik untuk mengukur rasio dari prediksi *true positif* dibandingkan dengan semua prediksi positif yang dilakukan. *Precision* digunakan untuk melihat seberapa akurat model berdasarkan total dari FP dan TP.

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive} \tag{3}$$

Recall (4) merupakan sebuah metrik untuk mengukur rasio dari *true positif* dibandingkan semua prediksi pada data positif yang ada. *Recall* digunakan untuk melihat seberapa akurat model berdasarkan total dari TP dan TN.

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative} \tag{4}$$

Miss Detection (5) merupakan sebuah metrik yang mengacu untuk mengukur kegagalan TP yang tidak terdeteksi.


$$Miss\ Detection = 1 - Recall \tag{5}$$

IV. HASIL EXPERIMEN DAN PENELITIAN

A. Implementasi

Dalam penelitian yang penerapan pada pendekatan *Convolutional Neural Network* (CNN) untuk menghasilkan klasifikasi jenis kerusakan badan kontainer. Dalam implementasi *input* (384, (384, 3)) hasil *output* yg telah di-*crop* YOLOv7 dengan tetap mempertahankan informasi penting. Selanjutnya proses 3.000 citra kontainer dengan jenis kerusakan yang tampak dinotasi 0 dan 1 dilanjutkan meringankan kinerja proses pembacaan *dataset* dengan metode *pickle* dengan skala pembagian 8:2 yaitu 2.400 data *training* dan 600 data *testing* dianalisis “*Flattening*” dan “*Fully-connected layer*” [14] yang memanfaatkan model *EfficientNetV2S* dan *ConvNeXtBase*. Gambar 5 hasil

penerapan klasifikasi jenis kerusakan kontainer dengan metode DCNN.



Gambar 5. Hasil Klasifikasi Citra Kontainer

B. Uji Coba dan Analisis Model *Machine Learning*

Hasil implementasi pendekatan *Convolutional Neural Network* (CNN) untuk menghasilkan klasifikasi jenis kerusakan badan kontainer. Selanjutnya dilakukan pengujian keakuratan pada 5 jenis kerusakan kontainer dengan 20% *dataset* yaitu 600 gambar citra kontainer yang dilakukan *training model* dengan model *EfficientNetV2S*:

Tabel 1. Hasil Pengujian dengan *EfficientNetV2S*

Jenis Kerusakan	Support	Precision	Recall	F1-Score
Cat	394	83%	80%	82%
Depos	82	44%	32%	37%
Kembang	50	68%	26%	38%
Pintu	7	100%	57%	73%
Korosi-Retak	132	62%	49%	55%


Sesuai hasil pengujian model *EfficientNetV2S* pada Tabel 1 mendapatkan hasil nilai skor F1 terboboti sebesar 68%. Peneliti meningkatkan data *training* menjadi 25% serta melakukan perluasan *dataset* dengan menambahkan fungsi *data generator* dalam pelatihan. Hal ini bertujuan untuk memastikan model dapat mencapai hasil yang lebih baik ketika melakukan *training*. Selain itu, penambahan fungsi *reduce learning rate* juga dilakukan untuk meningkatkan hasil dari model *EfficientNetV2S* pada Tabel 2. Hasil uji sistem menunjukkan penurunan bahwa model ini mencapai rata-rata nilai skor F1 terboboti sebesar 66%.

Tabel 2. Hasil Pengujian dengan *EfficientNetV2S*

Jenis Kerusakan	Support	Precision	Recall	F1-Score
Cat	499	84%	79%	81%
Depos	90	38%	11%	17%
Kembang	44	71%	11%	20%
Pintu	8	50%	12%	20%
Korosi-Retak	140	61%	56%	58%

Hasil analisis dari model *EfficientNetV2S* pada Tabel 1 dan Tabel 2 belum menunjukkan peningkatan yang signifikan terhadap jenis kerusakan "depos" dan "kembang" yang terlampir Gambar 6 (a) untuk kerusakan "depos" dan

terlampir Gambar 6 (b) untuk kerusakan "kembung". Hasil ini telah diverifikasi oleh tim inspeksi kerusakan kontainer pelabuhan.



6a 6b

Gambar 6. Hasil Prediksi Depos dan Kembung

Selanjutnya dilakukan pengujian keakuratan pada 5 jenis kerusakan kontainer dengan 20% dataset yaitu 600 gambar citra kontainer yang dilakukan training model dengan model ConvNeXtBase:

Tabel 3. Hasil Pengujian dengan ConvNeXtBase

Jenis Kerusakan	Support	Precision	Recall	F1-Score
Cat	394	83%	85%	84%
Depos	82	44%	34%	38%
Kembung	50	70%	32%	44%
Pintu	7	100%	57%	73%
Korosi-Retak	132	68%	48%	56%


Sesuai hasil pengujian model ConvNeXtBase pada Tabel 3 mendapatkan hasil nilai skor F1 terboboti sebesar 69%. Peneliti meningkatkan data training menjadi 25% serta melakukan perluasan dataset dengan menambahkan fungsi data generator dalam pelatihan. Hal ini bertujuan untuk memastikan model dapat mencapai hasil yang lebih baik ketika melakukan training. Selain itu, penambahan fungsi reduce learning rate juga dilakukan untuk meningkatkan hasil dari model ConvNeXtBase pada Tabel 4. Hasil uji sistem menunjukkan nilai skor F1 terboboti sebesar 72%.

Tabel 4. Hasil Pengujian dengan ConvNeXtBase

Jenis Kerusakan	Support	Precision	Recall	F1-Score
Cat	499	76%	94%	84%
Depos	90	46%	44%	45%
Kembung	44	77%	32%	45%
Pintu	8	100%	60%	75%
Korosi-Retak	140	61%	61%	61%

Hasil analisis dari model ConvNeXtBase pada Tabel 3 dan Tabel 4 belum menunjukkan peningkatan yang signifikan terhadap jenis kerusakan "depos" dan "kembung" yang terlampir Gambar 7 (a) untuk kerusakan "depos" dan terlampir Gambar 7 (b) untuk kerusakan "kembung". Hasil ini telah diverifikasi oleh tim inspeksi kerusakan kontainer

pelabuhan.




7a 7b

Gambar 7. Hasil Prediksi Depos dan Kembung

C. Uji Coba Sistem


Pengujian diterapkan dengan cara penyesuaian pengaturan learning rate, parameter layer dan parameter frame pada sistem dapat menghasilkan model terbaik. 3.000 citra kontainer dengan jenis kerusakan yang tampak dinotasi 0 dan 1 dilanjutkan meringankan kinerja proses pembacaan dataset dengan metode pickle dengan skala pembagian 8:2 yaitu 2400 data training dan 600 data testing pada Model EfficientNetV2S dan ConvNeXtBase.



8a 8b

Gambar 8. Hasil Prediksi Kerusakan Kontainer

Dari Gambar 8a merupakan hasil prediksi model ConvNeXtBase Serta Gambar 8b merupakan hasil prediksi model EfficientNetV2S dalam hasil prediksi dengan benar 2 jenis kerusakan kontainer cat dan retak dengan selisih tingkat akurasi.



9a 9b
Gambar 9. Hasil Prediksi Kerusakan Kontainer

Dari Gambar 9a merupakan hasil prediksi model *ConvNeXtBase* Serta Gambar 9b merupakan hasil prediksi model *EfficientNetV2S* dalam hasil prediksi dengan benar 2 jenis kerusakan kontainer cat dan retak dengan selisih tingkat akurasi.

Tabel 5. Hasil Pengujian Klasifikasi *multiclass*

Model CNN	Weighted avg		
	Precision	Recall	F1-Score
<i>EfficientNetV2S</i>	74%	62%	66%
<i>ConvNeXtBase</i>	70%	76%	72%

Hasil *confusion matrix* pengujian klasifikasi pada Tabel 5 sistem mampu prediksi jenis kerusakan kontainer dengan baik

V. KESIMPULAN

Dalam penelitian yang dilakukan terkait klasifikasi kerusakan pada kontainer menggunakan *Deep Convolutional Neural Network* (DCNN) dengansmodel *EfficientNetV2S* dan *ConvNeXtBase*, ditemukan bahwa sistem YOLOv7 dapat mengidentifikasi citra kontainer dengan tingkat akurasi yang impresif, mencapai 90%. Proses identifikasi ini meliputi tahapan pengumpulan *dataset*, pengolahan citra, pelatihan, dan pengujian, yang bertujuan untuk mendeteksi kontainer dan menentukan jenis kerusakan yang terjadi. Pembagian *dataset* kontainer pada data *training* 80% yaitu 2.400 gambar dan *training testing* 20% yaitu 600 gambar, membawa ke permukaan bahwa model *EfficientNetV2S* memiliki kemampuan prediksi kerusakan pada kontainer dengan Skor F1 Terboboti sebesar 66%, dengan *miss detection* terboboti 38%, sementara model *ConvNeXtBase* sedikit lebih unggul dengan Skor F1 Terboboti sebesar 72% dengan *miss detection* terboboti 24%. Hasil ini lebih rendah dari peneltian sebelumnya yang mendeteksi kontainer menggunakan *Fmask Rcn*n dengan *miss detection* terboboti 18,8% dan *Mask Rcn*n dengan *miss detection* terboboti 20,2%.

Penting untuk ditekankan bahwa tingkat *F1-Score* dalam mengenali kerusakan seperti depos dan kembang masih relatif

rendah dibandingkan dengan jenis kerusakan lain. Hal ini dikarenakan distribusi data untuk kerusakan tersebut tidak seimbang dan jumlahnya yang sangat terbatas. Selain itu, kerusakan jenis depos dan kembang ini juga secara visual sulit untuk terdeteksi, bahkan oleh para ahli, yang menambah kompleksitas dalam proses pengenalan otomatis melalui model yang diajukan.

REFERENSI

- [1] H. Gunawan, Suhartono, and M. E. Sianto, "Analisis Faktor-faktor Yang Berpengaruh terhadap Produktivitas Bongkar Muat Kontainer di Dermaga Berlian Surabaya (Studi Kasus PT. Pelayaran Meratus)," *Jurnal Ilmiah Widya Teknik*, vol. 7, no. 1, 2008. doi:10.33508/wt.v7i1.1263
- [2] H. M. N. I. Ronosentono, *Pengetahuan Dasar Tatalaksana Freight Forwarding*. Jakarta: Infomedika, 2006.
- [3] X. Li, Q. Liu, J. Wang, and J. Wu, "Container damage identification based on FMASK-RCNN," *Neural Computing for Advanced Applications*, pp. 12–22, 2020. doi:10.1007/978-981-15-7670-6_2.
- [4] S. Li, X. Zhao, and G. Zhou, "Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network," *Computer-Aided Civil and Infrastructure Engineering*, vol. 34, no. 7, pp. 616–634, 2019. doi:10.1111/mice.12433.
- [5] H. Maeda, Y. Sekimoto, T. Seto, T. Kashiya, and H. Omata, "Road damage detection and classification using deep neural networks with smartphone images," *Computer-Aided Civil and Infrastructure Engineering*, vol. 33, no. 12, pp. 1127–1141, 2018. doi:10.1111/mice.12387.
- [6] I. W. S. E. PUTRA, A. Y. Wijaya, and R. Soelaiman, "Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101," thesis, Institut Teknologi Sepuluh Nopember, Institut Teknologi Sepuluh Nopember, 2016
- [7] A. Peryanto, A. Yudhana, and R. Umar, "Klasifikasi Citra Menggunakan convolutional neural network Dan K Fold Cross validation," *Journal of Applied Informatics and Computing*, vol. 4, no. 1, pp. 45–51, 2020. doi:10.30871/jaic.v4i1.2017.
- [8] C.-Y. Lee, P. Gallagher, and Z. Tu, "Generalizing pooling functions in cnns: Mixed, gated, and Tree," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 40, no. 4, pp. 863–875, 2018. doi:10.1109/tpami.2017.2703082.
- [9] M. A. Abu, N. H. Indra, A. H. A. Rahman, N. A. Sapiee, and I. Ahmad, "A study on Image Classification based on Deep Learning and Tensorflow," *International Journal of Engineering Research and Technology*, vol. 12, no. 4, pp. 563–569, 2019.
- [10] K. Seetala, W. Birdsong, and Y. B. Reddy, "Image classification using tensorflow," *16th International Conference on Information Technology-New*

- Generations (ITNG 2019)*, pp. 485–488, 2019. doi:10.1007/978-3-030-14070-0_67
- [11] C. Tan *et al.*, “A Survey on Deep Transfer Learning,” *The 27th International Conference on Artificial Neural Networks (ICANN 2018)*.
- [12] Y. Wu, X. Qin, Y. Pan, and C. Yuan, “Convolution neural network based transfer learning for classification of flowers,” *2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP)*, 2018. doi:10.1109/siprocess.2018.8600536
- [13] M. Tan and Q. V. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” *Proceedings of the 36th International Conference on Machine Learning*, pp. 6105–6114, 2019.
- [14] C. Mahaputri, Y. Kristian, and E. Setyati, “Pengenalan Makanan tradisional Indonesia Beserta Bahan-Bahannya Dengan memanfaatkan DCNN transfer learning,” *Journal of Intelligent System and Computation*, vol. 4, no. 2, pp. 61–68, 2022. doi:10.52985/insyst.v4i2.252