

Klasifikasi Hasil Potret pada Cacat Produk *Spring Washer* menggunakan Metode *Transfer Learning Convolutional Neural Network*

Zendi Iklima*, Dinar Sakti C. N.

Teknik Elektro, Universitas Mercu Buana, Jakarta

*zendi.iklima@mercubuana.ac.id

Abstrak— Spring Washer merupakan komponen yang dapat digunakan untuk pengencang berulir. Spring Washer terbuat dari bahan logam lalu dibentuk ring bulat. Dalam Quality Prosedur Perusahaan produk yang diproduksi harus dicek kualitasnya agar tidak ada kecacatan produk terkirim ke pelanggan. Cacatan pada produk berbahan logam diantaranya adalah korosi pada produk. Pengecekan Spring Washer biasanya dilakukan secara visual manual oleh karyawan, hal ini memerlukan waktu yang tidak sebentar jika yang dicek memiliki kuantitas yang banyak. Dengan adanya Convolutional Neural Network (CNN) dilakukannya perancangan untuk mengklasifikasikan Spring Washer berkualitas baik dan korosi. Dalam penelitian ini dilakukan pembentukan sistem dengan Tiga model transfer learning CNN yaitu VGG16, MobileNet dan Xception. Pembentukan algoritma sistem menggunakan Google Colaboration dengan Bahasa pemrograman Python. Dataset diambil dari gambar produk Spring Washer sebanyak 1048 foto dengan keadaan yang berbeda, yaitu Spring Washer Bagus atau Korosi.

Kata Kunci— Spring Washer; Korosi; Convolutional Neural Network (CNN); MobileNet; Xception

DOI: 10.22441/jitkom.v9i1.003

Article History:

Received: July 24, 2024

Revised: February 20, 2025

Accepted: March 1, 2025

Published: March 10, 2025

I. PENDAHULUAN

Washer adalah plat berbentuk cakram dengan lubang yang mendistribusikan beban sekrup atau pengencang berulir lainnya. Sebagian besar fitur dan desain dasar komponen Washer ini sama. Namun, Washer dapat diproduksi untuk berbagai keperluan menyesuaikan dengan persyaratan produk dalam dunia industri. Salah satu macam produk Washer adalah Spring Washer. Spring Washer adalah komponen yang dapat digunakan untuk industri otomotif yang berfungsi sebagai sistem penahan unit Assembly dan dapat digunakan juga sebagai pegas pada mekanisme beban berat. Spring Washer perlu memiliki kualitas yang baik untuk menghindari kegagalan fungsi. [1] Washer terbuat dari bahan logam, salah satu kegagalan bahan logam adalah korosi. Korosi merupakan fenomena alam dan material khususnya logam yang memiliki suatu hubungan tidak sinergis atau berlawanan. Korosi adalah kerusakan material logam secara umum akibat dari reaksi dengan lingkungan sekitarnya, contoh kerusakan korosi adalah kerusakan permukaan logam secara morfologi, perubahan sifat struktur, perubahan sifat mekanis dan perubahan sifat kimia. Lingkungan yang menjadi penyebab korosi diantaranya adalah atmosfer, hujan asam, air laut dan kelembapan. [2]

Dalam sebuah Quality Prosedur Perusahaan, produk yang diproduksi harus dicek kesesuaiannya agar produk yang dipasarkan memiliki kualitas yang tepat dan jika terjadi kegagalan produk dapat dilakukan analisa perbaikan dan

penangannya. Sesuai dengan standart Internasional ISO 9001:2015 tentang Sistem Manajemen Mutu – Persyaratan pada point 8.7 dijelaskan tentang Kendali atas Produk tidak sesuai. Perlu dilakukan koreksi, pemisahan dan verifikasi produk agar tidak ada produk cacat yang terkirim ke pelanggan. Namun dalam aplikasi di Lapangan Kerja pengecekan korosi pada logam biasa dilakukan secara visual manual oleh operator. Jika jumlah produk yang diuji memiliki kuantitas yang banyak maka perlu adanya waktu yang lebih. Karena hal tersebut diatas diusulkan sebuah upaya pemisahan produk tidak layak menggunakan pendekatan pengklasifikasi citra menggunakan Convolution Neural Network (CNN). Convolutional Neural Network (CNN) merupakan salah satu metode Deep Learning (DL) yang mampu melakukan proses pembelajaran mandiri untuk mengenalkan objek, ekstraksi objek dan klasifikasi objek. [2]

Penelitian ini dilakukan berdasarkan oleh latar belakang yang telah dijabarkan. Penelitian bermaksud untuk mengimplementasikan metode Transfer Learning Convolutional Neural Network (CNN) dengan variasi percobaan model VGG16 [3], ResNet50 dan Xception serta menemukan model terbaik dari ketiga model CNN untuk proses klasifikasi produk Spring Washer melalui proses olah citra digital agar dapat membedakan antara Produk Spring Washer kualitas baik dengan produk yang mengalami korosi yang nantinya memudahkan Perusahaan dalam proses kendali atas produk yang tidak sesuai dengan harapan lebih mengefisienkan waktu dan tenaga kerja.

II. LITERATURE REVIEW

Pendekatan Artificial Intelligence menjadi topik yang menarik guna mengembangkan sistem otomatisasi khususnya dalam meningkatkan kualitas dan kuantitas produksi. Proses pembersihan korosi pada produk telah dilakukan misalnya dengan cara grinding yang diintegrasikan dengan robot yang terinstall dengan perangkat penangkap visual/kamera. Metode Qualified Image Detection (QID) digunakan untuk mendeteksi karat pada permukaan material logam selama proses penghilangan karat. Hasil dari penelitian ini menunjukkan bahwa metode QID dapat diterapkan untuk mendeteksi adanya korosi. Qualified Image Detection (QID) digunakan untuk mendeteksi karat pada permukaan material logam selama proses penghilangan karat dalam 5 kelompok penggrindingan. Persentase citra berkualitas yang berhasil dideteksi oleh QID dalam 5 kelompok percobaan adalah 97,2% [4]. Jaringan Syaraf Tiruan (CNN) sebagai usulan untuk efisiensi dalam akurasi akuisisi dan klasifikasi yang akurat dari gambar resolusi tinggi dengan memindai mikroskop elektron. Dengan melakukan augmentasi data yang sesuai pada gambar pelatihan. CNN berhasil dilatih pada sejumlah kecil gambar dan mencapai akurasi klasifikasi cacat yang tinggi. Dalam penelitian ini VGG16 digunakan sebagai arsitektur CNN dasar karena kemudahan penggunaannya. Untuk mengklasifikasi cacat hanya mengganti lapisan VGG16 yang terhubung penuh. Hasil dari penelitian ini adalah CNN berbasis VGG16 untuk klasifikasi cacat sebaris. CNN dilatih pada gambar cacat manufaktur aktual yang diambil oleh SEM setelah proses Cu. Akurasi klasifikasi adalah sekitar 95% pada dataset pelatihan kecil (30 gambar per jenis cacat). Augmentasi data yang tepat meningkatkan akurasi klasifikasi [5]. Automatisasi inspeksi pada cacat permukaan rel yang memiliki dampak negatif pada kenyamanan berkendara dan keselamatan lintasan, dan menjadi salah satu faktor utama menyebabkan penggelinciran. Oleh karena itu, metode Mask R-CNN dapat digunakan karena akurasinya yang tinggi dan hemat biaya. Basis data permukaan rel termasuk 1.040 citra (260 source image dan 780 augmented image) telah dibangun. Model segmentasi Mask R-CNN, telah dilatih ulang dan disempurnakan untuk memeriksa cacat permukaan rel dengan set data yang disesuaikan. Hasil eksperimen menunjukkan backbones ResNet101 mencapai kemampuan pemeriksaan yang lebih baik. Dengan learning rate 0,005, Mask R-CNN yang dilatih ulang dapat mencapai kinerja terbaik di bounding box dan mask predictions. [6]

Selain itu, beberapa model transfer learning CNN seperti VGG16, Resnet50, InceptionV3, DenseNet121, Xception dan MobileNet telah di uji pada beberapa kasus berbeda. Misalnya, model yang mengklasifikasikan kesegaran ikan bandeng yang dilatih menggunakan 153 citra. Model transfer learning yang dibandingkan ialah Xception, MobileNetV1, ResNet50 dan VGG16 dengan VGG16 mencapai kinerja terbaik dibandingkan arsitektur lainnya, dimana akurasi klasifikasi mencapai 97% [7]. Penelitian lainnya, dilakukan eksperimen untuk meklasifikasikan ukiran bermotif Jepara. Menggunakan cara membagi dataset berdasarkan color scape menjadi tiga bagian, yaitu LUV, RG dan YrCb dan melakukan percobaan pengujian dengan beberapa model CNN. Hasil pengujian penelitian ini menunjukkan bahwa Xception pada pengujian memiliki nilai

akurasi tertinggi, yaitu 95% untuk masing-masing dataset. Namun jika semua pengujian diterapkak pada identifikasi motif Jepara, ResNet50 memiliki nilai akurasi yang tertinggi dengan persentasi 84%, 79% dan 80% untuk masing masing color space [8].

Tabel 1. State of Art Summary

No	Method	Datasets	Acc
1	Qualified Image Detection (QID) [4]	-	97,2%
2	VGG16 [5]	30 citra per jenis cacat produk	95%
3	Xception, MobileNetV1, ResNet50 dan VGG16 [7]	153 citra ikan bandeng	97%
4	Mask R-CNN dengan ResNet-101 [6]	1.040 citra (260 source image dan 780 augmented image)	64,70%
5	VGG16, ResNet50, InceptionV3 dan Xception [8]	3005 citra per jenis motif ukiran jepara	95%

Berdasarkan Tabel 1 diatas, penelitian ini mengusulkan klasifikasi hasil potret pada cacat produk spring washer menggunakan metode transfer learning convolutional neural network. Adapun model transfer learning yang digunakan adalah VGG16, ResNet50 dan Xception.

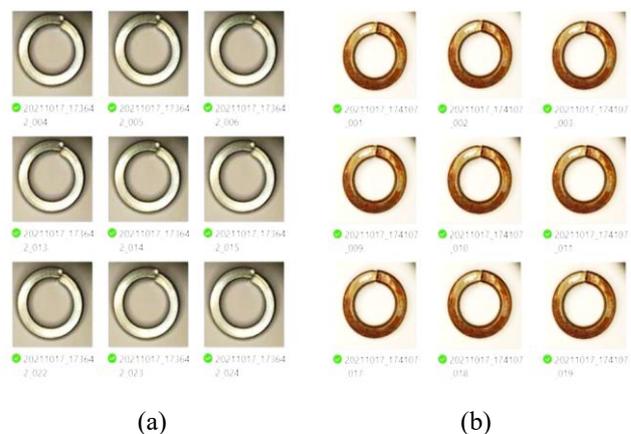
III. METODOLOGI PENELITIAN

Pada BAB ini menjelaskan metode yang diajukan sehingga menjadi solusi pada latar belakang penelitian yang telah dibahas.

A. Penelitian Kualitatif

Spring Wahser Dataset

Dataset yang diambil terdiri dari 523 foto spring washer kualitas non-korosi dan 561 foto spring washer kualitas korosi. Ukuran masingmasing foto adalah 1:1 dengan resolusi sebesar Dimensi keseluruhan citra adalah 3456x3456 pixel. Dataset diambil dengan latar belakang berwarna putih. Adapun sampel dataset yang telah tersedia seperti pada gambar.

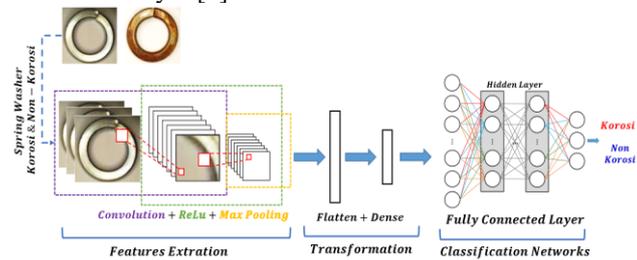


Gambar 1. Dataset Spring Washer (a) non-korosi dan (b) korosi

B. Penelitian Eksperimental

Convolutional Neural Networks (CNN)

Convolutional Neural Networks (CNN) adalah sub class dari deep neural networks yang dapat digunakan untuk menyelesaikan masalah pengenalan citra / gambar (image recognition). CNN menjadi sarana yang dapat dimanfaatkan untuk mengklasifikasikan gambar. Secara dimanis, CNN terdiri dari proses utama yaitu Features Extraction, dan Fully Connected Layer [9].



Gambar 2. Arsitektur CNN pada CXR Covid-19

Lapisan Konvolusional (Convolutional layer) merupakan lapisan dasar dari CNN yang menentukan ciri-ciri pola citra. Pada lapisan ini, gambar masukan dilewatkan melalui sebuah filter. Nilai-nilai yang dihasilkan dari pemfilteran terdiri dari peta fitur (feature map) yang terdiri dari beberapa kernel yang berpindah (slide) melalui pola untuk mengekstrak fitur tingkat rendah dan tinggi dalam pola tersebut. Stride adalah jumlah langkah yang disetel untuk menggeser matriks input.

Salah satu cara mereduksi waktu komputasi pada layer CNN, arsitektur CNN konvensional dapat dikonfigurasi dengan merubah layer pooling menjadi stride. Sebagai contoh, conv stride = 1 dilanjutkan dengan max pooling 2 bisa diganti dengan satu layer, yaitu conv stride = 2 dengan hasil yang hampir mirip. Misalkan f menunjukkan peta fitur yang dihasilkan oleh beberapa lapisan CNN, sedangkan N adalah jumlah filter di lapisan ini. Kemudian subsampling p-norm dengan pooling size m (atau setengah panjang $m/2$) dan langkah r diterapkan pada pemetaan fitur f adalah array 3 dimensi $s(f)$ dengan entri berikut [10]:

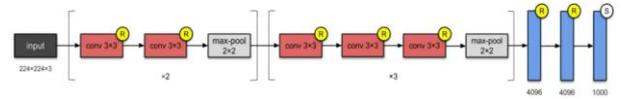
$$s_{i,j,u}(f) = \left(\sum_{h=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} \sum_{w=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} |f_g(h,w,i,j,u)|^p \right)^{\frac{1}{p}} \quad (1)$$

Dimana fungsi pemetaan dari s pada posisi stride f adalah $g(h,w,i,j,u) = (r \cdot i + h, r \cdot j + w, u)$. p adalah orde dari p-norm ($p \rightarrow \infty$ merepresentasikan max pooling). Jika $r > m$, pooling region tidak overlap. Definisi standar dari lapisan konvolusi c yang diterapkan pada peta fitur f dinyatakan sebagai berikut:

$$c_{i,j,o}(f) = \sigma \left(\sum_{h=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} \sum_{w=-\lfloor m/2 \rfloor}^{\lfloor m/2 \rfloor} \sum_{u=1}^N \theta_{h,w,u,o} \cdot f_g(h,w,i,j,u) \right) \quad (2)$$

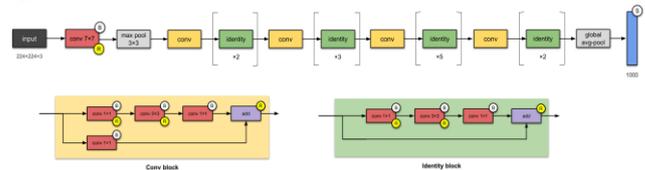
di mana θ adalah bobot konvolusi, $\sigma(\cdot)$ adalah fungsi aktivasi, biasanya aktivasi linier terkoreksi ReLU, dan $o \in [1, M]$ adalah jumlah fitur keluaran dari lapisan konvolusi. Dari kedua persamaan tersebut, terlihat bahwa biaya komputasi akan berkurang.

Arsitektur pada model transfer learning CNN yang akan digunakan sebagai klasifikator citra spring washer korosi/non-korosi. Adapun layer pada arsitektur VGG16 memiliki jumlah parameter dilatih sebanyak 138,357,544 dan direpresentasikan sebagai berikut:



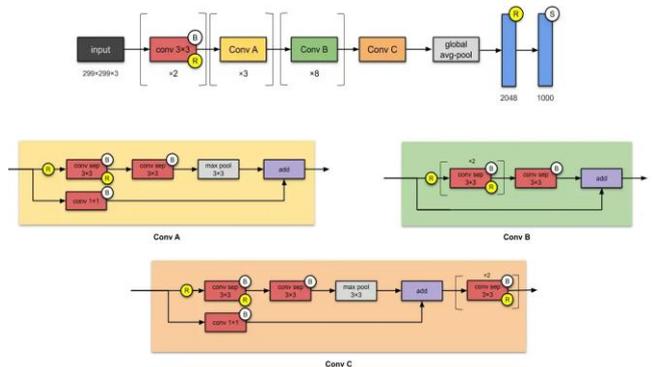
Gambar 3. Arsitektur VGG16

Adapun layer pada arsitektur ResNet50 memiliki jumlah parameter dilatih sebanyak 25,636,712 dan direpresentasikan sebagai berikut:



Gambar 4. Arsitektur ResNet50

Adapun layer pada arsitektur Xception memiliki jumlah parameter dilatih sebanyak 22,910,480 dan direpresentasikan sebagai berikut:



Gambar 5. Arsitektur Xception

Confusion Matrix / Matriks konfusi merupakan sebuah tabel pemetaan berbentuk matrix 2x2 yang terdiri dari banyaknya data uji yang diprediksi benar dan tidak benar oleh model klasifikasi. Tabel ini diperlukan untuk mengukur kinerja suatu model klasifikasi. Matriks konfusi dapat digunakan untuk menganalisis potensi pengklasifikasi dengan sempurna. Semua elemen diagonal menunjukkan hasil yang diklasifikasikan dengan benar. Hasil yang salah klasifikasi direpresentasikan pada diagonal mati dari matriks kebingungan. Oleh karena itu, pengklasifikasi terbaik akan memiliki matriks kebingungan dengan hanya elemen diagonal dan elemen lainnya diatur ke nol. Matriks konfusi menghasilkan nilai aktual dan nilai prediksi setelah proses klasifikasi. Efektivitas sistem ditentukan berdasarkan nilai berikut yang dihasilkan dalam matriks.

Tabel 2. Confusion Matrix

Predictive Class	Actual Class	
	True Positive (TP)	False Positive (FP)
False Negative (FN)	True Negative (TN)	

Entri dalam matriks kebingungan didefinisikan sebagai berikut: *True Positive rate* (TP) adalah jumlah total hasil atau

prediksi yang benar ketika kelas sebenarnya positif. *False Positive rate* (FP) adalah jumlah total hasil atau prediksi yang salah ketika kelas yang sebenarnya positif. *True Negative rate* (TN) adalah jumlah total hasil atau prediksi yang benar ketika kelas sebenarnya negatif. *False Negative rate* (FN) adalah jumlah total hasil atau prediksi yang salah ketika kelas sebenarnya negative.

Berdasarkan Tabel 2, Matriks konfusi merepresentasikan nilai TP yang diklasifikasikan dengan benar, nilai FP di kelas yang relevan saat seharusnya berada di kelas lain, dan nilai FN di kelas lain saat seharusnya berada di kelas yang relevan dan nilai TN yang diklasifikasikan dengan benar di kelas lain. Metrik kinerja yang paling sering digunakan untuk klasifikasi menurut nilai-nilai ini adalah nilai akurasi (Acc), presisi (P), sensitivitas (Sn), spesifisitas (Sp), dan skor-F. Perhitungan metrik kinerja ini menurut nilai-nilai dalam matriks kebingungan dibuat menurut Persamaan:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$P = \frac{TP}{TP + FP} \quad (4)$$

$$Sn = \frac{TP}{TP + FN} \quad (5)$$

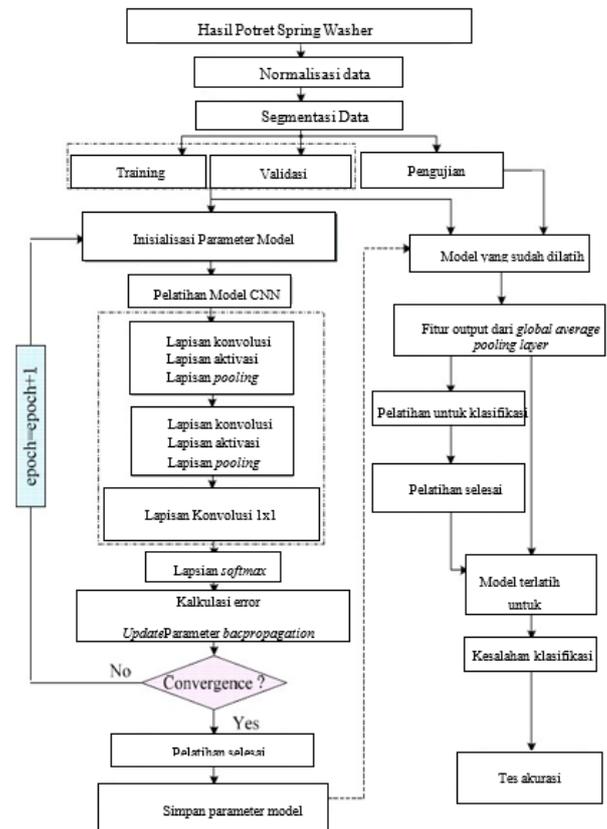
$$Sp = \frac{TN}{TN + FP} \quad (6)$$

$$F - score = 2 \times \frac{P \times Sn}{P + Sn} \quad (7)$$

Pada sub ini akan dipaparkan diagram blok sistem, dimana tiap- tiap blok silih berhubungan antara yang satu dengan yang lain. Diagram blok mempunyai sebagian guna yaitu: menarangkan metode kerja sesuatu sistem secara simpel, menganalisa metode kerja sistem serta memudahkan dalam memeriksa kesalahan sesuatu sistem yang dibentuk. Ada pula diagram blok dari sistem yang dirancang merupakan semacam yang diperlihatkan pada gambar 6.

Pada gambar 6 ada diagram alir yang menampilkan secara garis besar proses berjalannya program pada riset ini. Semacam yang bisa dilihat pada gambar secara garis besar ada 2 proses yaitu proses pelatihan dan proses pengujian. Pertama- tama akan dibahas mengenai proses pelatihan terlebih dulu, pada proses pelatihan ada sebagian tahapan antara lain pelatihan dengan multilayer CNN yang dikombinasikan dengan lapisan softmax kemudian akan dihitung nilai eror pada tiap epochnya, nilai eror ini akan dikurangi dengan memakai *backpropagation* algorithm pada tiap epoch. Bila menggunakan pre- trained model proses pelatihan tidak butuh dicoba sebab model sudah mempunyai pengetahuan serta keahlian buat mengklasifikasikan gambar. Proses berikutnya merupakan proses pengujian ataupun testing, model CNN yang telah dilatih

digunakan buat mengekstraksi fitur- fitur yang terdapat pada gambar sehabis itu dilanjutkan dengan mengukur kesalahan dari klasifikasi serta keluarannya berupa akurasi dari pengujian.



Gambar 6. Diagram Alir Penelitian

IV. HASIL DAN ANALISA

Dataset terdiri dari dua kelas. Dari dataset Spring Washer OK berjumlah 523 ditambah dataset Spring Washer karat berjumlah 561, total seluruh dataset adalah 1084. Dataset dibagi menjadi Data Pelatihan, Data Validasi dan Data Pengujian. Data untuk pengujian terdiri dari 607 data. Data untuk validasi terdiri dari 151 data. Data untuk test pengujian terdiri dari 326 data. Distribusi dataset ini untuk ke Tiga Model CNN yang diuji coba. Adapun gambar sebelah kiri adalah Spring Washer karat dan sebelah kanan adalah Spring Washer baik.



Gambar 7. Dustribusi Dataset\

Untuk mengetahui rangkuman dari model yang telah dibangun, gunakan perintah `model.summary()`. Model Summary yang didapat dari VGG16 adalah model ini mencacah sampai dengan 5 kali Max Pooling. Dari input 224, 224, 3 sampai dengan output 7, 7, 512. Hasil dari arsitektur VGG mendapatkan nilai total params berjumlah 138.357.544. Nilai Trainable

params berjumlah 138.357.544 dan untuk non-trainable params berjumlah 0. Dari Model Summary CNN model MobileNet memperlihatkan arsitektur MobileNet yang memecah atau memecah input melewati 13 Convolution Filter, dimana data awal input dari nilai [224, 224, 3] menjadi [1,1, 1000). Dari arsitektur MobileNet mendapatkan nilai total params berjumlah 4.253.864. Nilai Trainable params berjumlah 4.231.976 dan untuk non-trainable params berjumlah 21,888.

Dari model Summary CNN model Xception input awal bernilai [299,299, 3]. Dari arsitektur Xception mendapatkan nilai total params berjumlah 22.910.480. Nilai Trainable params berjumlah 22.855.952 dan untuk non-trainable params berjumlah 54.528.

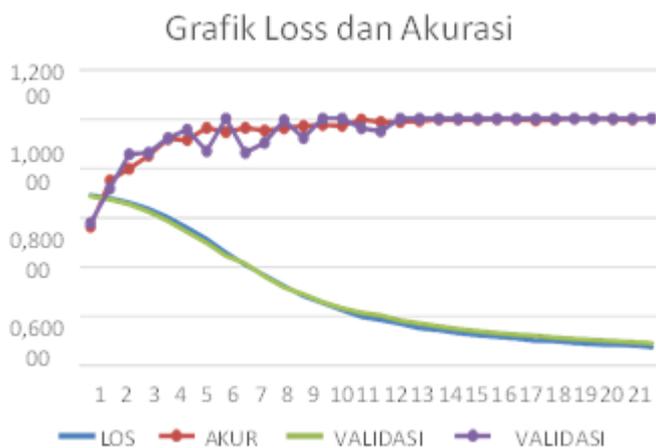
A. Pelatihan Data

Pelatihan menggunakan beberapa model, diantaranya adalah VGG16, MobileNet dan Xception. Dataset sudah dilatih terlebih dahulu, Hyperparameter yang digunakan saat proses pelatihan adalah sebagai berikut:

Tabel 3. Hyperparameter Sistem

Deskripsi	Klasifikasi <i>Spring Washer</i> Karat dan Baik
Model	<i>VGG16, MobileNet, Xception</i>
Dataset	Hasil foto produk <i>Spring Washer</i>
Ukuran <i>batch</i>	32
<i>Epochs</i>	30
<i>Learning rate</i>	0,0001
Resolusi Gambar	3120x3120
Fungsi Optimasi	<i>Adam Optimizer</i>

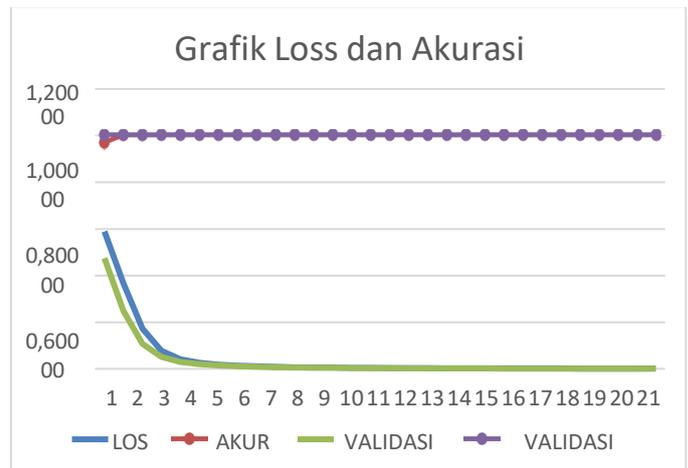
Pelatihan dataset menggunakan Model CNN VGG16, dengan epoch sebanyak 30 kali dengan durasi pelatihan 53 menit 3 detik memiliki hasil akhir Loss saat training berada diantara nilai 0,68806 hingga 0,07210. Sedangkan nilai Loss pada proses validasi berkisar antara nilai 0,68378 hingga 0,0877. Nilai akurasi adalah diantara nilai 0,56013 hingga 1,000 dan Nilai Validasi Akurasi akhir 1,000.



Gambar 8. Grafik Loss dan Akurasi VGG16

Pelatihan dataset menggunakan Model CNN MobileNet, dengan epoch sebanyak 30 kali dengan durasi pelatihan selama 51 menit 46 detik memiliki hasil akhir Loss saat training berada diantara nilai 0,58928 hingga 0,00092. Sedangkan nilai Loss pada proses validasi berkisar antara nilai 0,47537 hingga

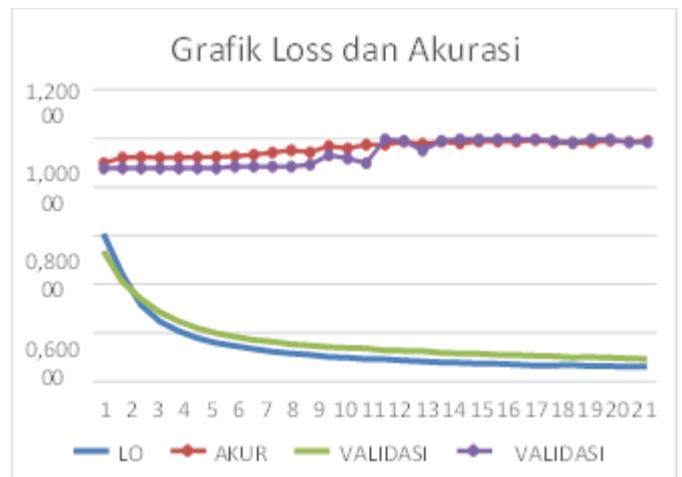
0,00062. Nilai akurasi adalah diantara nilai 0,96705 hingga 1,00000 dan Nilai Validasi Akurasi mencapai nilai akhir 1,0000.



Gambar 9. Grafik Loss dan Akurasi MobileNet

Berdasarkan yang dilihat pada Gambar 9. nilai Loss saat validasi lebih kecil dibandingkan dengan nilai Loss saat proses pelatihan jaringan. Pada Validasi Loss memiliki nilai lebih kecil, sehingga nilai akurasi semakin baik. Grafik akurasi juga memiliki nilai yang konstan sejak pelatihan ke 2.

Pelatihan dataset menggunakan Model CNN Xception, dengan epoch sebanyak 30 kali dengan durasi pelatihan selama 58 menit 43 detik memiliki hasil akhir bahwa Loss saat training berada diantara nilai 0,60693 hingga 0,06140. Sedangkan nilai Loss pada proses validasi berkisar antara nilai 0,53691 hingga 0,09279. Nilai akurasi adalah diantara nilai 0,894564 hingga 0,98682 dan Nilai Validasi Akurasi mencapai nilai akhir 0,980132.



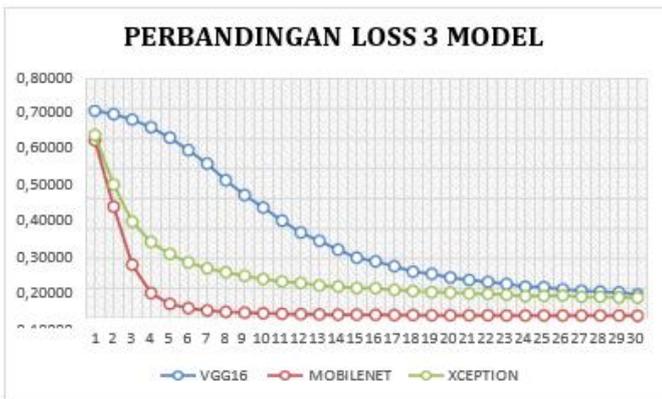
Gambar 10. Grafik Loss dan Akurasi Xception

Berdasarkan yang dilihat pada Gambar 10 nilai Loss saat validasi lebih tinggi dibandingkan dengan nilai Loss saat proses pelatihan jaringan. Hal ini dapat disebabkan oleh jumlah data yang tidak seimbang antara pelatihan dan validasi.

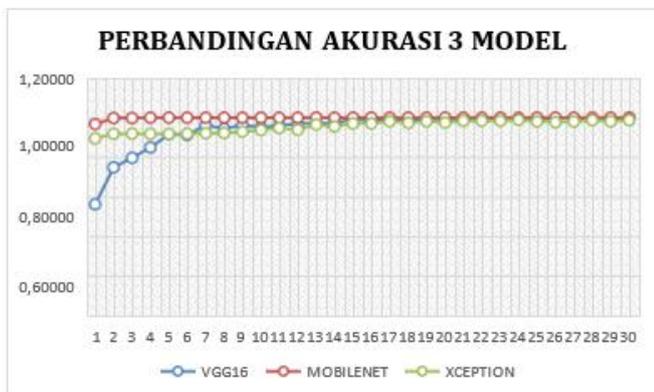
Pada Gambar 11. Grafik perbandingan Loss dan training dari tiga model yang digunakan yaitu VGG16, MobileNet dan

Xception. Grafik menunjukkan nilai Loss yang paling baik dimiliki oleh model MobileNet, dimana nilai Loss menjadi semakin landau dengan nilai Loss yang paling kecil dari Model VGG16 dan Xception.

Pada Gambar 11 Grafik perbandingan akurasi dari tiga model yang digunakan yaitu VGG16, MobileNet dan Xception. Grafik menunjukkan nilai akurasi yang paling baik dimiliki oleh model VGG16 dan MobileNet, dimana nilai akurasi menjadi semakin semakin meningkat dan men capai akurasi 100%.



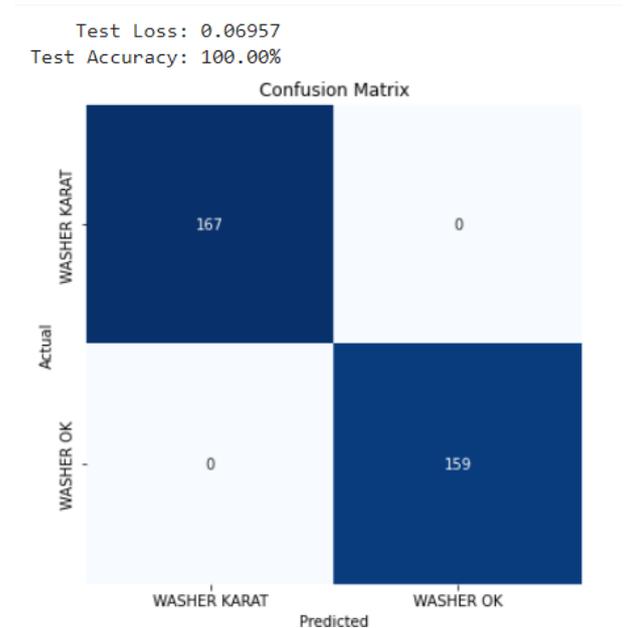
Gambar 11. Grafik Perbandingan Loss 3 Model CNN



Gambar 12. Perbandingan Akurasi 3 Model CNN

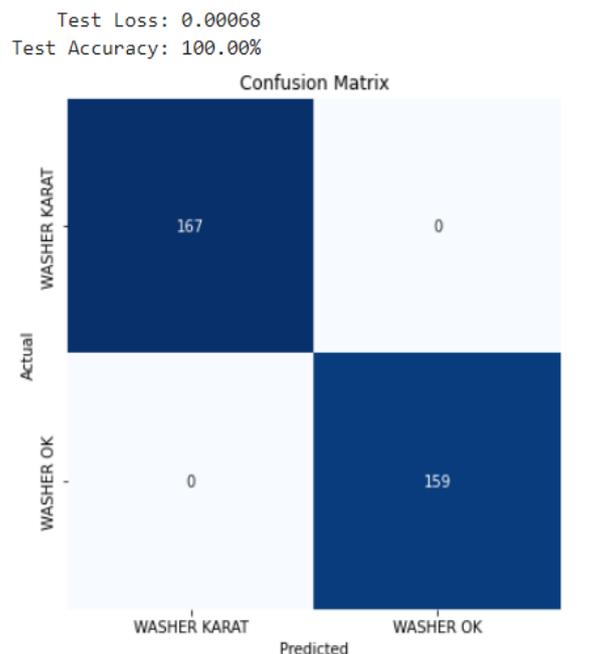
Hasil evaluasi Confusion Matrix dari masing-masing model CNN memiliki nilai yang berbeda, adapun nilainya sebagai berikut:

Hasil Confusion Matrix dari Klasifikasi Model CNN VGG16 seperti pada Gambar 13. Dalam Gambar diperlihatkan Jumlah True Positif adalah 167, True Negatif adalah 159, False Positif adalah 0, dan False Negatif adalah 0. Hasil ini diartikan bahwa Model VGG16 dapat mengklasifikasi produk Spring Washer Karat dengan ketepatan yang bagus dan memiliki nilai akurasi sebesar 100 %.



Gambar 13. Confusion Matrix VGG16

Hasil Confusion Matrix dari Klasifikasi Model CNN MobileNet seperti pada Gambar 15. Dalam Gambar diperlihatkan Jumlah True Positif adalah 163, True Negatif adalah 159, False Positif adalah 0, dan False Negatif adalah 0. Hasil ini diartikan bahwa Model MobileNet dapat mengklasifikasi produk Spring Washer Ka rat dan baik dengan tepat sesuai dengan akurasi yaitu 100%.



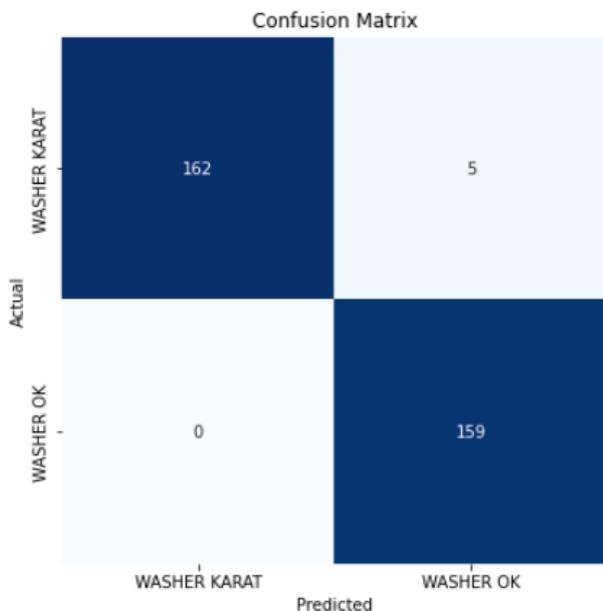
Gambar 14. Confusion Matrix MobileNet

Hasil Confusion Matrix dari Klasifikasi Model CNN Xception seperti pada Gambar 16. Dalam Gambar diperlihatkan Jumlah True Positif adalah 162, True Negatif adalah 159, False Positif adalah 5, dan False Negatif adalah 0. Hasil ini diartikan bahwa Model Xception kurang tepat dalam mengklasifikasi

produk *Spring Washer* karat dan baik karena kelolosan saat mengklasifikasi.

Test Loss: 0.07387

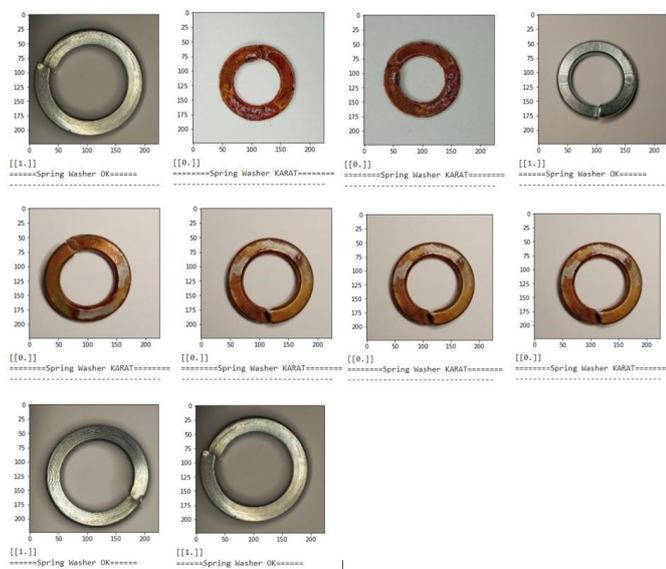
Test Accuracy: 98.47%



Gambar 15. Confusion Matrix Xception

Pengujian sistem dilakukan dengan cara memberikan 10 sampel gambar produk *Spring Washer* yang kemudian sistem akan mengklasifikasikan sampel tersebut dan menyimpulkan setiap gambarnya tentang apakah gambar tersebut merupakan sampel *Spring Washer* yang berkualitas baik atau yang karat. Adapun hasil prediksi sebagai berikut:

Dilakukan pengujian sistem dengan memberikan 10 gambar *Spring Washer* dengan keadaan yang berbeda, yaitu karat dan baik. Adapun hasil pengujian klasifikasi *Spring Washer* menggunakan model CNN VGG16 sebagai berikut:



Gambar 16. Pengujian Sistem Model VGG16

Pada gambar menampilkan hasil pengujian sistem model VGG16, dari 10 gambar jawaban yang dihasilkan adalah benar

semua. Sesuai dengan akurasi yang ada pada sistem jika sistem memiliki tingkat akurasi di nilai 100%.

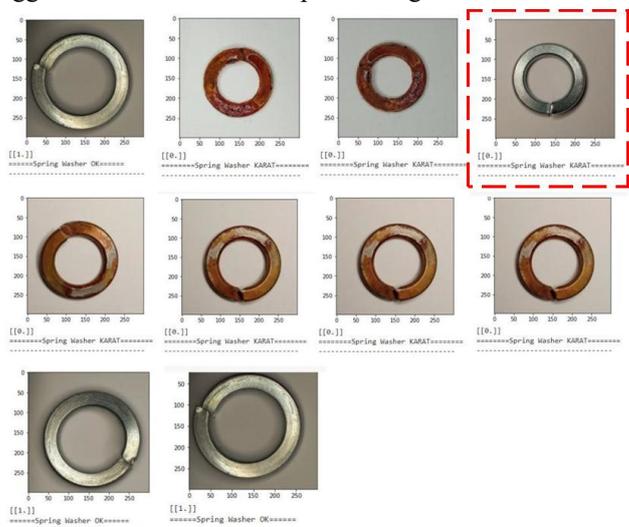
Dilakukan pengujian sistem dengan memberikan 10 gambar *Spring Washer* dengan keadaan yang berbeda, yaitu karat dan baik. Adapun hasil pengujian klasifikasi *Spring Washer* menggunakan model CNN MobileNet sebagai berikut:



Gambar 17. Pengujian Sistem Model MobileNet

Pada gambar menampilkan hasil pengujian sistem model MobileNet, dari 10 gambar jawaban yang dihasilkan adalah benar semua. Sesuai dengan akurasi yang ada pada sistem jika sistem memiliki tingkat akurasi di nilai 100%.

Dilakukan pengujian sistem dengan memberikan 10 gambar *Spring Washer* dengan keadaan yang berbeda, yaitu karat dan baik. Adapun hasil pengujian klasifikasi *Spring Washer* menggunakan model CNN Xception sebagai berikut:



Gambar 18. Pengujian Sistem Model Xception

Pada gambar menampilkan hasil pengujian sistem model Xception, dari 10 gambar terdapat 1 jawaban yang tidak tepat yaitu gambar nomor 4, jawaban yang seharusnya adalah *Spring Washer* OK namun sistem menjawab Karat. Sesuai dengan

akurasi yang ada pada sistem jika sistem memiliki tingkat akurasi di nilai 90%.

V. KESIMPULAN

Membangun sistem Convolutional Neural Network dengan model VGG16, MobileNet dan Xception dapat dilakukan menggunakan Google Colaboration dengan Dataset total awal sebanyak 1048 data lalu Dataset dibagi menjadi 3, yaitu Data Pelatihan sebanyak 607 data, Data Validasi sebanyak 151 data, dan Data Test Pengujian sebanyak 326 data. Sedangkan hasil akhir pelatihan yang didapat berbeda dari setiap model yang dilakukan pelatihan. Hasil akhir diringkas dalam Tabel 4.

Tabel 4. Perbandingan Performa Model

PARAMETER	MODEL		
	<i>VGG16</i>	<i>MobileNet</i>	<i>Xception</i>
<i>Wall Time</i>	00.53.03	00.51.46	00.58.43
<i>Loss</i>	0,06957	0,00068	0,07387
Akurasi	100,00%	100,00%	98,47%
Nilai Pengujian	10/10	10/10	9/10

Berdasarkan Tabel 4 model VGG16 dan MobileNet sama-sama memiliki akurasi sebesar 100% dan berhasil menjawab uji coba klasifikasi gambar dengan jawaban benar 10 dari 10 pertanyaan, berbeda dengan model Xception dengan akurasi 98,47% hanya mampu menjawab 9 jawaban benar dari 10 pertanyaan. Namun dari segi waktu pelatihan, model MobileNet memiliki waktu pelatihan lebih sedikit dari pada model VGG16. Dari hasil Analisa bahwanya model MobileNet adalah model CNN yang paling efisien untuk mendeteksi Karat pada produk Spring Washer.

DAFTAR PUSTAKA

- [1] M. Tegar and E. Sutoyo, "analisis kegagalan spring washer material sk-5 lapisan electroplating zinc", *Ame (Aplikasi Mekanika Dan Energi) Jurnal Ilmiah Teknik Mesin*, vol. 5, no. 2, p. 53, 2019. <https://doi.org/10.32832/ame.v5i2.2471>.
- [2] G. Priyotomo, "Buku Praktis Korosi Dan Logam Untuk Mahasiswa", *nulisbuku.com*, 2015
- [3] R. Rismiyati and A. Luthfiarta, "VGG16 Transfer Learning Architecture for Salak Fruit Quality Classification," *Telematika*, vol. 18, no. 1, p. 37, Mar. 2021, doi: <https://doi.org/10.31315/telematika.v18i1.4025>.
- [4] Y. Tian, G. Zhang, J. Ma, & S. Ma, "Automated rust detection via digital image recognition during grinding work process", 2018 IEEE International Conference on Information and Automation (ICIA), p. 318-323, 2018. <https://doi.org/10.1109/icinfa.2018.8812345>
- [5] A. Fujishiro, Y. Nagamura, T. Usami, & M. Inoue, "Minimization of cnn training data by using data augmentation for inline defect classification", 2020 International Symposium on Semiconductor Manufacturing (ISSM), p. 1-4, 2020. <https://doi.org/10.1109/issm51728.2020.9377504>
- [6] Y. Tian, G. Zhang, J. Ma, & S. Ma, "Automated rust detection via digital image recognition during grinding work process", 2018 IEEE International Conference on Information and Automation (ICIA), p. 318-323, 2018. <https://doi.org/10.1109/icinfa.2018.8812345>
- [7] E. Prasetyo, R. Purbaningtyas, R. Adityo, E. Prabowo, & A. Ferdiansyah, "perbandingan convolution neural network untuk klasifikasi kesegaran ikan bandeng pada citra mata", *Jurnal Teknologi Informasi Dan Ilmu Komputer*, vol. 8, no. 3, p. 601, 2021. <https://doi.org/10.25126/jtiik.2021834369>
- [8] Sandhopi, Lukman Zaman P.C.S.W, and Yosi Kristian, "Identification of Jepara Motifs on Carvings by Utilizing Convolutional Neural Network", *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 9, no. 4, pp. 403-413, Dec. 2020.
- [9] M. Alwanda, R. Ramadhan, & D. Alamsyah, "Implementasi metode convolutional neural network menggunakan arsitektur lenet-5 untuk pengenalan doodle", *Jurnal Algoritme*, vol. 1, no. 1, p. 45-56, 2020. <https://doi.org/10.35957/algoritme.v1i1.434>
- [10] E. Ihsanto, K. Ramli, D. Sudiana, and T. S. Gunawan, "Fast and Accurate Algorithm for ECG Authentication Using Residual Depthwise Separable Convolutional Neural Networks," *Applied Sciences*, vol. 10, no. 9, pp. 3304–3304, May 2020, doi: <https://doi.org/10.3390/app10093304>.