

Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Kecacatan Pada Proses Welding di Perusahaan Manufacturing

Nandang Saefulloh*, Jamaludin Indra, Rahmat, Ayu Ratna Juwita

¹Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Buana Perjuangan, Karawang, Indonesia
Email: ¹*If20.nandangsaefulloh@mhs.ubpkarawang.ac.id, ²jamaludinindra@ubpkarawang.ac.id, ³rahmat@ubpkarawang.ac.id, ⁴ayurj@ubpkarawang.ac.id

Email Penulis Korespondensi: If20.nandangsaefulloh@mhs

Submitted: 11/06/2024; Accepted: 29/06/2024; Published: 30/06/2024

Abstrak—Industri manufaktur menjadi salah satu sektor terbesar di Indonesia, didorong dengan meningkatnya permintaan dari masyarakat. Faktor utama yang menjadi perhatian dalam memenuhi kebutuhan pasar, baik lokal maupun internasional yakni terkait kualitas produk. Dalam upaya memastikan standar kualitas yang tinggi, proses produksi memerlukan kontrol kualitas yang ketat. Salah satu masalah yang sering muncul dalam quality control yakni kecacatan pada proses pengelasan (welding) yang mempengaruhi waktu siklus pengecekan. Untuk mengatasi hal ini, Pendekatan Convolutional Neural Network (CNN) dengan arsitektur VGG-16 dapat membantu mengklasifikasikan kecacatan pada proses pengelasan. Metode ini tidak hanya mempercepat proses klasifikasi cacat, tetapi juga meningkatkan akurasi identifikasi cacat produk. Tahapan penerapan metode ini meliputi persiapan dataset, preprocessing data, perancangan model CNN, pelatihan model, dan evaluasi kinerja. Hasil evaluasi menunjukkan bahwa penggunaan teknologi deteksi cacat secara otomatis, terutama dengan skenario data yang seimbang, dapat meningkatkan kinerja kontrol kualitas dengan signifikan. Akurasi, presisi, recall, dan F1-score mencapai tingkat yang sangat baik, yakni mencapai 92%. Dengan demikian, penelitian ini memberikan kontribusi penting dalam upaya meningkatkan efisiensi produksi dan meningkatkan kualitas produk dalam industri manufaktur mesin sepeda motor di Indonesia. Diharapkan bahwa penggunaan teknologi ini akan membantu perusahaan-perusahaan manufaktur dalam mengidentifikasi dan mengatasi cacat produksi dengan lebih efektif, sehingga meningkatkan daya saing industri manufaktur Indonesia secara keseluruhan.

Kata Kunci: Cacat; CNN; VGG-16

Abstract—Manufacturing industry has become one of the largest sectors in Indonesia, driven by increasing demand from the public. A primary concern to meet both local and international market needs is product quality. In ensuring high-quality standards, production processes require strict quality control. One common issue in quality control is defects occurring during the welding process, which significantly affects inspection cycle times. To address this, the Convolutional Neural Network (CNN) approach with VGG-16 architecture can help classify defects in the welding process. This method not only expedites the defect classification process but also enhances the accuracy of identifying product defects. The stages of implementing this method include dataset preparation, data preprocessing, CNN model design, model training, and performance evaluation. Evaluation results demonstrate that the use of automatic defect detection technology, especially with balanced data scenarios, can significantly improve quality control performance. Accuracy, precision, recall, and F1-score achieve excellent levels, reaching 92%. Thus, this research provides a significant contribution to enhancing production efficiency and improving product quality in the motorcycle manufacturing industry in Indonesia. It is hoped that the use of this technology will assist manufacturing companies in identifying and addressing production defects more effectively, thereby enhancing the overall competitiveness of Indonesia's manufacturing industry.

Keywords: Defect; CNN; VGG-16

1. PENDAHULUAN

Industri manufaktur mesin sepeda motor menjadi perusahaan terbesar di Indonesia, hal tersebut dipengaruhi oleh kebutuhan masyarakat yang semakin meningkat [1]. Banyaknya kebutuhan pasar lokal sampai pasar internasional, tentunya kualitas menjadi faktor penting yang harus diterapkan dalam produksi [2]. Dalam proses produksi pastinya memerlukan *quality control* untuk mengetahui kualitas produk apakah baik (OK) atau tidak (NG) [3]. Barang dapat dikatakan OK jika sesuai dengan standar *quality control*, sedangkan barang NG tidak sesuai dan tidak layak untuk di distribusi ke masyarakat.

Setiap perusahaan memiliki standar *quality control* yang berbeda-beda, akan tetapi memiliki makna yang sama untuk menentukan OK dan NG [4]. Pada proses *Quality control* sering menemukan kesalahan pada proses produksi salah satunya kecacatan pada proses pengelasan (*welding*) [5]. Namun, hal ini menyebabkan *cycle time* pada proses pengecekan karena membutuhkan waktu yang cukup lama [6]. Masalah tersebut dapat diatasi dengan teknologi *deep learning* salah satunya dengan bantuan *Computer Vision* yang dapat digunakan untuk mendeteksi produk NG. Teknologi tersebut yang akan mengklasifikasikan tingkat kecacatan produk pada proses pengelasan (*welding*) [7].

Klasifikasi merupakan sebuah tahapan dari pencarian suatu kumpulan model (fungsi) yang dapat membedakan kelas dari setiap data ataupun konsep. Secara singkat klasifikasi merupakan cara mengelompokkan objek kedalam sebuah kelas tertentu [19]. Adapun tujuan dari klasifikasi diartikan dalam penelitian [20] yaitu memperkirakan kelas dari sebuah objek yang labelnya tidak ketehui sebelumnya. Teknologi deep learning dapat mengenali pola yang cukup kompleks, dapat mengenali berbagai gambar pada proses pelatihan sehingga menghasilkan akurasi yang cukup tinggi. Telah dilakukan penelitian klasifikasi pada citra menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur VGG-16 untuk mengklasifikasi citra [8], [9], [10], [11], [12].

Terdapat pembahasan klasifikasi tingkat kecacatan pada Ban, jumlah data yang digunakan 1039 citra ban. Preprocessing yang dilakukan terdapat *resize* citra menjadi 224 x 224, kemudian terdapat data latih untuk pelatihan model CNN kemudian diuji dan menghasilkan klasifikasi. Hasil akurasi mendapatkan nilai 87%, *precision* 81%, *recall* 96%, *f-1 score* 88% dengan parameter *Resize* 224 x 224, *Optimizer* SGD, *Epoch* 70, *batch size* 16 dan *learning rate* 0,0001. Sementara itu Sutanty, E., & Astuti, (2023) [13] mengklasifikasikan jenis sampah menggunakan metode CNN dengan arsitektur VGG-16. Arsitektur VGG-16 pada penelitian ini menggunakan 16 lapisan layer yang terdiri atas 13 lapisan layer konvolusi dan 3 lapisan fully-connected. Pelatihan model menggunakan library tensorflow dengan rasio split data 7:1.5:1.5 untuk data latih, data test dan data validasi. Hasil penelitian ini mendapatkan akurasi sebesar 82.52%.


Penelitian lain membahas terkait pengenalan jenis-jenis kendaraan menggunakan metode Convolutional Neural Network (CNN). Data yang digunakan dalam penelitian ini sebanyak 120 citra yang terdiri dari citra mobil, motor dan sepeda. Hasil uji coba dan evaluasi model terhadap tiga jenis kendaraan menggunakan package Keras menunjukkan akurasi sebesar 94,4% pada tahap pelatihan dan 73,3% pada tahap pengujian. Metode algoritma CNN telah digunakan pada timbangan pintar, metode CNN digunakan agar dapat mengenali jenis sayuran. Alat yang digunakan yakni mikrokontroler ESP32-CAM karena relatif murah dibandingkan dengan menggunakan Raspberry Pi. Dataset terdiri dari 600 citra terdiri dari 4 jenis yaitu tomat, kubis, wortel dan kentang [14]. Hasil penelitian ini menggunakan *load cell* kapasitas 5 kg dan memiliki selisih 2 gram, akurasi yang didapatkan mencapai 90%.

Selanjutnya A Kirana et al., (2020) [15] menggunakan metode CNN proses pengenalan objek dilakukan secara mandiri, ekstraksi objek serta klasifikasi. Arsitektur CNN terdiri dari 3 yakni lapisan *konvolusi*, lapisan *max-pooling* dan klasifikasi Tahapan lapisan konvolusi terdiri dari *neuron* yang tersusun membentuk sekumpulan filter dengan panjang dan tinggi (*pixels*). Pengenalan pola aksara sunda berdasarkan hasil uji citra, metode CNN mampu mengklasifikasi dalam mengenali citra Aksara Sunda. Berikutnya peneliti lain membahas algoritma CNN terkait klasifikasi kecacatan lembaran baja secara otomatis. Model yang digunakan yakni transfer learning dari 5 model *Resnet50*, *Inception V3*, *Xception*, *VGG-16* dan *VGG-19*. Jumlah dataset pada penelitian ini 1.800 citra yang nantinya digunakan untuk data pelatihan, data validasi dan data pengujian. Tahapannya dimulai dengan preprocessing terdiri dari normalisasi, *augmentasi* dan *one-hot encoding*, setelah itu proses pelatihan dan validasi menggunakan *transfer learning* dari 5 *pre-trained* model. Hasil pada metode ini memiliki nilai akurasi serta kinerja yang baik yaitu sebesar 98%.

Berdasarkan penelitian sebelumnya, belum ada pembahasan terkait topik klasifikasi kecacatan dalam proses *welding* [13], [16], [17], [18]. Oleh sebab itu, penelitian ini berfokus pada klasifikasi kecacatan pada proses *welding* menggunakan algoritma *Convolutional Neural Network* (CNN) dengan tambahan arsitektur VGG-16. Metode ini salah satu teknik deep learning yang terbukti efektif dalam pengolahan citra dan deteksi pola. VGG-16, sebagai salah satu arsitektur CNN yang populer, memiliki keunggulan dalam hal kedalaman jaringan dan kemampuan untuk menangkap fitur-fitur penting dari data citra. Dalam penelitian ini, dataset yang digunakan terdiri dari gambar hasil proses *welding* yang telah diberi label sesuai dengan kondisi cacat atau tidaknya. Data ini kemudian diproses melalui beberapa tahapan seperti preprocessing untuk meningkatkan kualitas citra dan mengurangi noise. Setelah itu, data dimasukkan ke dalam model CNN dengan arsitektur VGG-16 untuk dilatih dan diuji. Tujuan utama dari penelitian ini adalah untuk mengembangkan model yang mampu mengklasifikasikan kecacatan pada hasil *welding* dengan cepat dan akurat. Dengan demikian, penelitian ini memberikan solusi inovatif dan praktis untuk tantangan dalam *quality control*, khususnya dalam proses *welding*.

2. METODOLOGI PENELITIAN

Tahap metodologi penelitian terdiri dari beberapa tahapan proses yang antara lain diawali dengan pengumpulan data, dilanjutkan dengan tahap *preprocessing* untuk menyiapkan data, agar data sudah fit untuk masuk dalam tahap *processing*. Selanjutnya terdapat tahap implementasi algoritma *Convolutional Neural Network* (CNN) guna membangun model untuk mengklasifikasikan citra hasil pengelasan. Tahapan diakhiri dengan tahap evaluasi, di mana tahap ini berisi pengujian dari model yang dirancang, serta interpretasi hasil pengujian.




Gambar 1. Diagram Alur Penelitian

Dapat dilihat pada Gambar 1 tahapan penelitian diawali oleh tahap pemilihan data, di mana pada tahap ini akan dilakukan pencarian data melalui situs yang ada di internet. Tahapan selanjutnya merupakan tahap *preprocessing*, di

mana tahap ini meliputi pengskalaan data, mengatur jumlah batch yang akan digunakan pada tahap pelatihan, serta mengkategorikan data. Proses pengkategorian data akan diawali dengan tahap penyortiran data, di mana data a gambar akan dipisahkan sesuai dengan kelas yang akan ditentukan nantinya. Setelah tahap *preprocessing*, dilanjutkan dengan tahap implemetasi algoritma. Pada tahap ini akan menerapkan algoritma *Convolutional Neural Network* (CNN) dan juga menambahkan pretrained model dari keras application untuk dijadikan arsitektur tambahan dalam proses pelatihan. Selanjutnya setelah berhasil mengimplementasikan algoritma, dilanjutkan dengan tahap evaluasi algoritma, di mana pada tahap evaluasi, model yang dirancang akan diuji performanya dengan beberapa pengujian seperti *confusion matrix*, dan *classification report*.

2.1 Dataset

Pada tahap ini dilakukan pengumpulan data untuk digunakan dalam pelatihan model klasifikasi citra hasil pengelasan. Jumlah data yang digunakan sebanyak 1844 Citra serta dibagi menjadi empat kelas yang terdiri dari pengelasan baik (*good welding*), pengelasan buruk (*bad welding*), Pengelasan sedang (*pores welding*) dan retak (*crack*). Seluruh citra pada dataset dibagi peruntukannya sebagai data latih, data validasi dan data uji. Data latih menggunakan 80% dari keseluruhan data, data validasi menggunakan 10% dan data uji menggunakan 10% dari total dataset. Gambar 2 menampilkan citra dataset yang digunakan.



Gambar 2. *Good Welding* (a), *Crack Welding* (b), *Pores Welding* (c) dan *Bad Welding* (d).

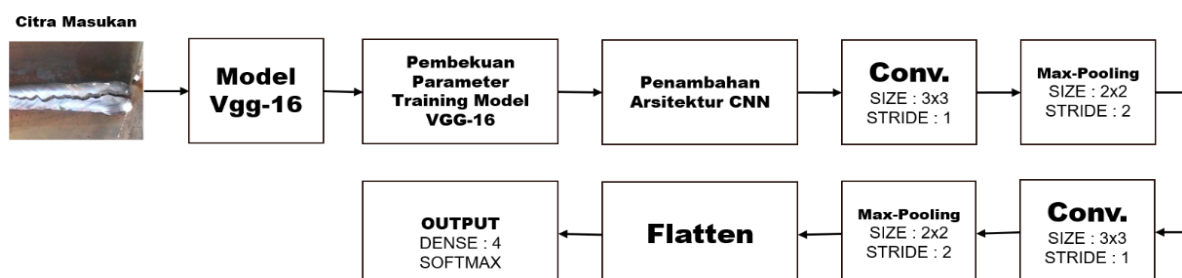
Pada Gambar 2 terdapat ilustrasi dari 4 kelas yang nantinya akan dijadikan sebagai target klasifikasi, di mana kelas yang ditandai dengan huruf “a” merupakan hasil gambar pengelasan yang baik. Pengelasan yang baik ditandai dengan hasil yang rapih tanpa terlihat bercak, berpori-pori, serta tidak pecah. Selanjutnya kelas yang ditandai dengan huruf “b” merupakan kelas dari hasil pengelasan yang pecah, di mana hasil pengelasan akan terlihat terbelah atau patah. Selanjutnya kelas yang ditandai oleh huruf “c” merupakan kelas dari hasil pengelasan yang berpori-pori, di mana hasil pengelasan terlihat tidak rapih, serta terdapat banyak bahan pengelasan yang tercecer yang menyerupai pori-pori. Hal ini disebabkan oleh udara atau gas yang terkurung dalam proses pengelasan. Terakhir kelas yang di tandai dengan huruf “d” merupakan hasil pengelasan yang buruk, di mana hasil yang didapat tidak rata bahkan terdapat bagian yang tidak ter las atau putus.

2.2 Preprocessing

Pada tahap *preprocessing* citra, dilakukan beberapa proses yang diterapkan pada setiap citra agar data siap digunakan dan dapat disesuaikan pada model arsitektur yang dibangun. *Preprocessing* dilakukan menggunakan fitur data generator dari pustaka Keras untuk menambahkan variasi dalam tahap pelatihan seperti *zooming*, *rotating*, *flipping*, dan *scalling*. Dilakukan juga *bauching* dalam menentukan jumlah sampel yang digunakan. Data generator akan menghasilkan beberapa hasil pra-pemrosesan seperti data yang sudah di perbesar dan diputar seperti sebelumnya hal ini dapat menambah variasi dalam proses pelatihan yang akan digunakan pada model pre-training VGG-16 dan lapisan *fully connected*.

2.3 Implementasi Algoritma

Model yang digunakan pada implementasi ini menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur VGG-16 sebagai model *pre-trained network*. Model CNN dan arsitektur VGG-16 digunakan untuk mengklasifikasi citra kecacatan proses *welding* atau pengelasan yang akan diketahui jenis kecacatannya.



Gambar 3. Proses Transfer Learning

Dapat dilihat pada Gambar 3 tahapan diawali dengan pemilihan model pretrained yang digunakan, dalam hal ini model VGG16 akan digunakan. Selanjutnya setelah mengimplementasikan model *pretrained* dilakukan pembekuan parameter *training* dari model tersebut. Hal ini dilakukan karena dalam tahap pelatihan model VGG16 hanya akan dijadikan sebagai wadah untuk membantu proses pengidentifikasian objek. Setelah parameter dibekukan dilanjutkan dengan penambahan arsitektur CNN yang dirancang. Pada tahap ini terjadi proses konvolusi sebanyak 2 layer begitupun dengan layer *maxpooling*. Berikutnya dilanjutkan dengan tahap *flattening*, di mana pada tahap *flattening* data akan dibuat menjadi matriks 1 dimensi atau diratakan yang diakhiri dengan *layer dense* dengan fungsi aktivasi *softmax*. Adapun penggunaan fungsi aktivasi *softmax* dikarenakan data yang diolah memiliki kelas lebih dari 2 atau *multiclass classification*. Sehingga fungsi aktivasi ini diharapkan sesuai dengan tujuan pengklasifikasian lebih dari 2 kelas.

2.4 Evaluasi

Tahapan pengujian ini untuk mengevaluasi dan menganalisis pengolahan dataset dari model CNN. Evaluasi yang digunakan yaitu *confusion matrix* dengan *classification report* tujuannya untuk mengetahui performa algoritma *Convolutional Neural Network*. Adapun penggunaan *library classification report* bertujuan untuk menampilkan rangkuman nilai *precision*, *recall*, *F1-score*, dan *accuracy*. Akurasi (*Accuracy*) mengukur seberapa banyak prediksi yang benar dibandingkan dengan total prediksi.

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Prediksi}} \quad (1)$$

Presisi (*Precision*) mengukur seberapa banyak dari instansi yang diberi label positif oleh model benar-benar positif.

$$\text{Presisi} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \quad (2)$$

Recall (*Sensitivitas* atau *True Positive Rate*) mengukur seberapa banyak dari total instansi yang sebenarnya positif yang ditemukan oleh model.

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \quad (3)$$

F1-score adalah ukuran gabungan dari *presisi* dan *recall*, menghasilkan skor yang mencoba mencapai keseimbangan antara keduanya.

$$\text{F1 - Score} = \frac{\text{presisi} \times \text{recall}}{\text{presisi} + \text{recall}} \quad (4)$$

Confusion matrix Memiliki empat kombinasi yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), *False Negative* (FN).

3. HASIL DAN PEMBAHASAN

Tahap hasil dan pembahasan diawali dengan pencarian dataset, di mana pada tahap ini ditemukan dataset yang didapat dari situs “*roboflow*”, yang terdiri dari total 1844 citra hasil pengelasan, dengan total 4 kelas. Setelah dataset ditentukan, berlanjut dalam tahap *preprocessing*, di mana tahap ini terdiri dari beberapa bagian dimulai dengan tahap *scalling*, *batching*, dan pengkategorian. Pada tahap *scaling* citra dibuat menjadi serupa sebesar 128x128 piksel, selanjutnya pada tahap *batching* ditentukan sebesar 32 batch. Selanjutnya pada tahap pengkategorian data, data kumpulan citra akan dikumpulkan menjadi sebuah data frame yang terdiri dari 2 kolom, *filepath* dan kelas dari citra. Setelah tahap *preprocessing* dilakukan, dilanjutkan dengan tahap implementasi algoritma, di mana pada tahap ini akan digunakan algoritma *Convolutional Neural Network* (CNN) dengan juga menambahkan arsitektur VGG16 dari keras *application*. Pada proses *training* jumlah epoch yang ditentukan sebesar 100 epoch dengan menerapkan *dropout* sebesar 0.5 pada setiap layer konvolusi, lalu pada layer optimizer, digunakan optimizer adam dengan *learning rate* sebesar 0.001. Selanjutnya tahapan akhir dari penelitian dilakukan dengan mengevaluasi model yang dirancang dengan menginterpretasikan *confusion matrix*, dan *classification report* guna menghitung nilai akurasi, *precision*, *recall*, dan *f1-score*.

3.1 Preprocessing

Hasil visual pada tahap *preprocessing* dapat digunakan untuk keperluan analisis yang lebih lanjut. Dataset yang sebelumnya terpisah telah berhasil digabung menjadi satu *dataframe* melalui proses pengolahan data. Langkah-langkah hasil *preprocessing* yang diterapkan terhadap dataset ini ditunjukkan pada Tabel 1.

Tabel 1. Keterangan Data

Dataset	
Nama Kelas	Jumlah Data
<i>Good Welding</i>	461
<i>Bad Welding</i>	461
<i>Pores</i>	461
<i>Crack</i>	461

Dapat dilihat pada Tabel 1 merupakan data yang sudah menjadi data *frame*, dengan jumlah data disetiap kelasnya sama sebesar 461 citra. Proses berikutnya data dibagi menjadi 3 bagian meliputi data pelatihan (*training*) 80%, data pengujian (*testing*) 10% dan data validasi (*validation*) 10% dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pembagian Data

Data Training	Data Testing	Data Validation
1472	184	185

Berdasarkan Tabel 2 diketahui bahwa data yang digunakan sebagai data latih sebanyak 1472 citra, 184 citra sebagai data *testing*, dan 185 citra sebagai data *validation*. Proses berikutnya meliputi perubahan dimensi citra menjadi 128 x 128 piksel dengan *batch* sebesar 32. Kemudian proses pelatihan mengkombinasikan metode data *augmentasi* yang bertujuan agar dataset beragam dan proses ekstraksi fitur semakin meningkat. *Augmentasi* yang dilakukan berupa *rescalling*, *rotation*, *zoom*, *horizontal flipping*, dan *shear*.

3.2 Hasil Implementasi Algoritma

Pada tahap ini dilakukan proses *transfer learning* dengan menggunakan *pretrained* model VGG16 yang ada pada keras *application*. Tahapan awal *transfer learning* yang dilakukan pada proses kali ini yaitu dengan memasukan *pretrained* model yang ada pada keras *application*. Selanjutnya setelah model berhasil di masukan, dapat dilihat hasil *summary* dari paramater model yang dipilih. Adapun hasil *summary* paramater *pretrained* model VGG16 dapat dilihat pada Tabel 3.

Tabel 3. Total Parameter Model VGG16

Total Parameter	Trainable Parameter	Non-Trainable Parameter
14,880,932	14,880,932	0

Dapat dilihat pada Tabel 3 total parameter yang didapat dari *pretrained* model VGG16 sebesar 14.880.932. Selanjutnya total *trainable* parameter yang didapat sebesar 166.244. Sedangkan *non-trainable* parameter yang didapat sebesar 14.714.688. Parameter *trainable* yang didapat merupakan parameter yang nantinya akan digunakan pada proses pelatihan model dalam pengenalan objek. Sedangkan *nontrainable* parameter merupakan paramaeter yang tidak digunakan dalam proses pelatihan model. Berikutnya setelah memasukan *pretrained* model, langkah selanjutnya yang dilakukan yaitu membuat model VGG16 beku dengan cara menetapkan *trainable* parameter VGG16 *false*. Setelah model VGG16 beku, tahapan selanjutnya adalah dengan menimpa model VGG16 dengan model CNN yang dirancang. Hal ini menyebabkan semua *trainable* parameter dari VGG16 sebelumnya akan berubah menjadi *nontrainable* parameter, yang menandakan bahwa parameter VGG16 hanya akan dijadikan *base* model saja dalam tahap pelatihan. Adapaun pada Tabel 4 merupakan hasil parameter dari arsitektur VGG16 ditambah dengan arsitektur CNN yang dirancang.

Tabel 4. Total Parameter model VGG16 Ditambahkan dengan Model CNN

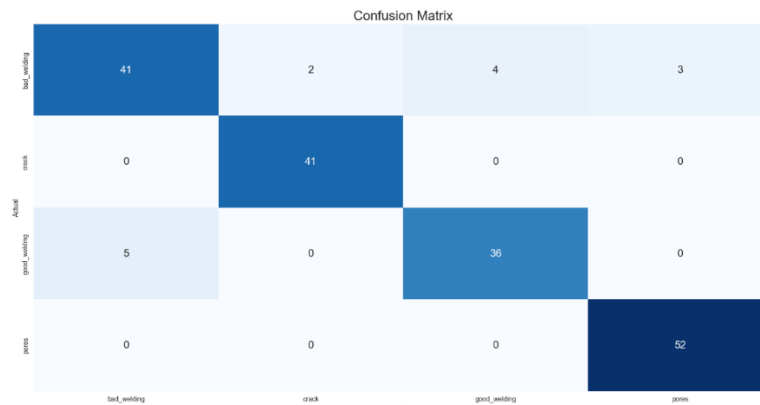
Total Parameter	Trainable Parameter	Non-Trainable Parameter
14,880,932	166.244	14.714.688

Pada Tabel 4 merupakan hasil parameter dari arsitektur VGG16 dengan tambahan arsitektur CNN yang dirancang. Total parameter yang didapat sebesar 14.880.932, dengan 166.244 *trainable* parameter dan 14.714.688 *non-trainable* parameter. Parameter *trainable* yang terdapat pada Tabel 4 merupakan parameter yang nantinya akan digunakan pada tahap pelatihan. Sedangkan *nontrainable* parameter yang terdapat pada Tabel 4 merupakan hasil parameter yang didapat dengan membekukan model VGG16 seperti penjelasan sebelumnya, di mana parameter ini hanya akan dijadikan *base* dalam tahap pelatihan.

3.3 Hasil Evaluasi

Pada tahap ini evaluasi dilakukan dengan menggunakan *confusion matrix* dan *classification report* untuk mengukur kinerja model yang dirancang. Dalam visualisasi tabel *confusion matrix* terdapat 2 sumbu utama yaitu sumbu yang mendefinisikan nilai aktual dari setiap kelas, serta sumbu yang menunjukkan prediksi dari setiap kelas. Pengujian ini dilakukan dengan menggunakan batch 32 dan epoch sebesar 100 pada proses pelatihannya, serta dimensi dari citra

yang digunakan ditetapkan sebesar 128x128 piksel. Adapun pada Gambar 4 merupakan ilustrasi dari hasil *confusion matrix*.



Gambar 4. Hasil Confusion Matrix

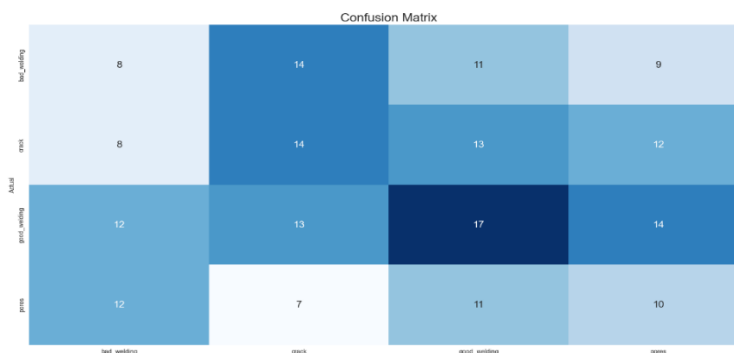
Dapat dilihat pada Gambar 4 merupakan ilustrasi dari pengujian *confusion matrix* dengan menggunakan data testing, dalam hal ini data yang digunakan berjumlah 87 citra. Berdasarkan hasil pengujian diketahui bahwa kelas dengan *miss classification* tertinggi didapat oleh kelas *bad welding* sebesar 9 citra. Sedangkan kelas dengan *miss classification* terendah didapat oleh kelas *crack* dan *pores* dengan tidak ada citra yang terklasifikasi tidak sesuai dengan kelasnya. Dalam hal ini yang dimaksudkan dengan *miss classification* ditunjukkan pada setiap kelas yang tidak terklasifikasi sesuai dengan kelas aktualnya. Selanjutnya merupakan pengujian dengan menggunakan *library classification report* yang dapat mengukur nilai akurasi, *precision*, *recall*, dan, *F1-score*. Adapun hasilnya dapat dilihat pada Tabel 5.

Tabel 5. Hasil Classification Report

Nama Kelas Citra	Classification Report			
	Precision	Recall	F1-score	Accuracy
Bad Welding	89%	82%	85%	92%
Crack	95%	100%	98%	
Good Welding	90%	88%	89%	
Pores	95%	100%	97%	

Dapat dilihat pada Tabel 5 merupakan hasil *classification report*, di mana nilai tertinggi dari *precision*, *recall*, dan *F1-score* akan ditandai dengan arsiran berwarna abu-abu. Berdasarkan hasil pada Tabel 5 diketahui bahwa nilai *precision* tertinggi didapat oleh kelas *crack* dan *pores* sebesar 95% dengan nilai terendah sebesar 89%, yang menandakan model cenderung tidak memberikan banyak *false positive*. Selanjutnya nilai *recall* tertinggi didapatkan oleh kelas *crack* dan *pores* sebesar 100% dengan nilai terendah sebesar 82% pada kelas *bad welding*. Hal ini menandakan bahwa model yang dirancang cenderung baik dalam mengidentifikasi objek dengan sedikit *false negative*. Berikutnya nilai *F1-score* tertinggi didapatkan oleh kelas *crack* sebesar 98% dengan nilai terendah yang didapatkan oleh kelas *bad welding*. Menandakan bahwa model yang dirancang sudah memiliki nilai *precision* dan *recall* yang realtif baik.

Tahap pengujian akhir model akan dilakukan dengan menguji model yang dirancang untuk langsung mengklasifikasikan data validasi yang sudah dipisahkan pada tahap pemisahan data, di mana data validasi memiliki jumlah citra sebanyak 185 citra dari total keseluruhan kelas. Adapun ilustrasi dari *confusion matrix* dapat dilihat pada Gambar 5.



Gambar 5. Hasil Confusion Matrix Pengujian Data Validasi

Dapat dilihat pada Gambar 5 merupakan hasil *confusion matrix* dari pengujian menggunakan data validasi, adapun hasil yang di representasikan terdiri dari kelas yang di prediksi pada sumbu x, dan kelas yang sebenarnya pada sumbu y, Hasil yang didapat dalam pengujian pada Gambar 5 terlihat masih sangat banyak kelas yang terklasifikasi tidak sesuai dengan kelas sebenarnya. Seperti kelas dengan jumlah klasifikasi yang tidak sesuai dengan kelas aslinya tertinggi didapatkan oleh kelas “*good_welding*” dengan jumlah citra yang tidak sesuai terklasifikasi dengan kelasnya sebesar 39 citra dari total 56 citra yang di validasi. Selain itu kelas yang mendapatkan hasil kesalahan klasifikasi citra yaitu kelas “*pores*” dengan hanya 30 citra dari total citra yang di validasi sebesar 40 citra. Berdasarkan hasil dari pengujian *confusion matrix* dengan menggunakan data validasi diketahui bahwa model yang dirancang tidak memiliki hasil yang baik dalam membedakan setiap kelas pada masing-masing citra dalam data validasi.

Selanjutnya pada tahap pengujian data validasi dengan menggunakan *library confusion matrix* untuk menghitung nilai akurasi, *precision*, *recall*, dan *f1-score*. Menggunakan total 185 citra dari total kelas keseluruhan, di mana hasil dari pengujian di jabarkan dan dapat dilihat pada Tabel 6.

Tabel 6. Hasil *Classification Report* dengan Data Validasi

Nama Kelas Citra	Classification Report			
	Precision	Recall	F1-score	Accuracy
<i>Bad Welding</i>	20%	19%	20%	26%
<i>Crack</i>	29%	30%	29%	
<i>Good Welding</i>	33%	30%	31%	
<i>Pores</i>	22%	25%	24%	

Dapat dilihat pada Tabel 6 terdapat hasil dari pengujian menggunakan *library classification report* untuk menghitung nilai *precision*, *recall*, dan *f1-score*. Terdapat dua kolom yang terdiri dari nama kelas citra dan kolom hasil nilai *precision*, *recall*, dan *f1-score*. Adapun nilai akurasi yang didapat pada pengujian sebesar 26% dengan hasil tertinggi dari nilai *precision* didapatkan oleh kelas “*good_welding*” sebesar 33%, dan untuk nilai *precision* terendah didapatkan oleh kelas “*bad_welding*” sebesar 20%. Selanjutnya untuk nilai *recall* tertinggi didapatkan oleh kelas “*good_welding*” dan kelas “*crack*” sebesar 30%, sementara untuk nilai *recall* terendah didapatkan oleh kelas “*bad_welding*” sebesar 19%. Berikutnya nilai dalam pengujian data validasi nilai *f1-score* tertinggi didapatkan oleh kelas “*good_welding*” sebesar 31%, sedangkan untuk nilai terendah dari perhitungan *f1-score* didapatkan oleh kelas “*bad_welding*” sebesar 20%. Berdasarkan hasil pengujian *classification report* dalam perhitungan nilai *precision*, *recall*, dan *f1-score*, diketahui bahwa model belum mendapatkan hasil yang baik dengan total macro *average precision* sebesar 26%, *recall* sebesar 26%, dan *f1-score* sebesar 26%. Sehingga dapat disimpulkan pada pengujian *confusion matrix* dan *classification report* dengan menggunakan data validasi mendapatkan hasil yang cukup buruk. Sehingga model belum bisa diaplikasikan langsung untuk mengklasifikasi citra hasil pengelasan.

4. KESIMPULAN

Berdasarkan hasil pengujian menggunakan *confusion matrix* dan *classification report*, model yang dibuat menunjukkan performa yang sangat baik dalam pengujian menggunakan data test dengan beberapa metrik utama. Akurasi model mencapai 92%, yang menunjukkan bahwa model mampu memprediksi dengan benar sebagian besar data yang diuji. Selain itu, metrik lain seperti *precision*, *recall*, dan *F1-score* masing-masing juga mencapai 92%. *Precision* sebesar 92% menunjukkan bahwa dari semua prediksi positif yang dibuat oleh model 92% benar-benar positif. *Recall* sebesar 92% menunjukkan bahwa dari semua data yang sebenarnya positif, model berhasil mengidentifikasi 92% dengan benar, yang berarti model tidak terlalu banyak melewatkan data positif. *F1-score*, yang merupakan rata-rata harmonis dari *precision*, dan *recall*, juga berada di angka 92%, menegaskan keseimbangan antara kedua metrik tersebut. Namun pengujian dengan menggunakan data validasi mendapatkan hasil yang sebaliknya atau cenderung buruk dengan mendapatkan nilai akurasi sebesar 26%, *precision* sebesar 26%, *recall* sebesar 26%, dan *f1-score* sebesar 26%. Dari hasil tersebut, dapat disimpulkan bahwa model yang dirancang belum mampu memberikan performa yang konsisten dan tidak dapat diandalkan dalam mengklasifikasi citra data sesuai dengan tujuan yang telah ditentukan. Rendahnya nilai akurasi, *precision*, *recall*, dan *F1-score* yang didapat dengan pengujian menggunakan data latih menunjukkan bahwa model ini masih perlu diteliti karna hasil klasifikasi yang cenderung *overfitting*. Oleh karena itu, model ini dapat dianggap belum siap untuk diterapkan dalam skenario nyata untuk memberikan kontribusi signifikan dalam meningkatkan efisiensi dan efektivitas proses yang diotomatisasi. Hasil ini juga menunjukkan bahwa pendekatan dan metode yang digunakan dalam pengembangan model sangat memerlukan peninjauan ulang guna mencari alasan terkait mengapa model yang dirancang *overfitting*.

REFERENCES

- [1] J. Aprilion and W. Simamora, “SISTEM PAKAR MENDETEKSI KERUSAKAN SEPEDA MOTOR N-MAX MENGGUNAKAN METODE FORWARD CHAINING BERBASIS ANDROID Expert System To Detect Damage To N-Max Motorbikes Using Forward chaining Method Based on Android,” 2021.



- [2] D. Raya, A. Yunan, and R. I. Rosihan, "Analisis Upaya Menurunkan Cacat Produk Crank Case LH pada Proses Die Casting dengan Metode PDCA dan FMEA di PT. Suzuki Indo Mobil/Motor," 2020.
- [3] A. S. Putra and P. Yuliarty, "PEMBUATAN PROGRAM MACHINING TIME GUARD MESIN CNC UNTUK MENJAGA CYCLE TIME MESIN PADA PROSES PRODUKSI SEPEDA MOTOR MATIC," vol. XVI, no. 1, pp. 101–115, 2022.
- [4] K. Lee, S. Yi, S. Hyun, and C. Kim, "Review on the Recent Welding Research with Application of CNN-Based Deep Learning Part I: Models and Applications," *Journal of Welding and Joining*, vol. 39, no. 1, pp. 10–19, Feb. 2021, doi: 10.5781/jwj.2021.39.1.1.
- [5] M. S. H. Nizam, S. Marizan, S. A. Zaki, and A. R. Mohd Zamzuri, "Vision based identification and classification of weld defects in welding environments: A review," *Indian Journal of Science and Technology*, vol. 9, no. 20. Indian Society for Education and Environment, May 01, 2016. doi: 10.17485/ijst/2016/v9i20/82779.
- [6] R. Juniardo, L. Tobing, and H. H. Azwir, "PENINGKATAN PRODUKTIVITAS PENGECEKAN QUALITY CONTROL PART BRACKET D14N DENGAN PERANCANGAN JIG DI PT. TIANURA TEKNO KARYA," 2020.
- [7] Erifive. Pranatal, "Analisa Cacat Pengelasan Smaw Pada Posisi 2G Pada Baja Material a36 Dengan Variasi Arus Dan Sudut Pengelasan," *Jurnal Sumberdaya Bumi Berkelanjutan (SEMATAN) 1.1* : 257-263., 2022.
- [8] A. Ludfi and A. Shidiq, "Klasifikasi Kecacatan Ban Untuk Mengendalikan Kualitas Produk Menggunakan Model CNN Dengan Arsitektur VGG-16 Classification Of Tire Defect To Control Product Quality Using Cnn Model With VGG-16 Architecture," 2022. [Online]. Available: www.kaggle.com.
- [9] F. Nurona Cahya et al., "SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," 2021. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [10] A. M. Rizki and N. Marina, "KLASIFIKASI KERUSAKAN BANGUNAN SEKOLAH MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK DENGAN PRE-TRAINED MODEL VGG-16," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 24, no. 3, pp. 197–206, 2021, doi: 10.35760/tr.2019.v24i3.2396.
- [11] S. Kumaresan, K. S. J. Aultrin, S. S. Kumar, and M. D. Anand, "Transfer Learning with CNN for Classification of Weld Defect," *IEEE Access*, vol. 9, pp. 95097–95108, 2021, doi: 10.1109/ACCESS.2021.3093487.
- [12] S. J. Oh, M. J. Jung, C. Lim, and S. C. Shin, "Automatic detection of welding defects using faster R-CNN," *Applied Sciences (Switzerland)*, vol. 10, no. 23, pp. 1–10, Dec. 2020, doi: 10.3390/app10238629.
- [13] Ety Sutanty, Maukar, Dina Kusuma Astuti, and Handayani, "Penerapan Model Arsitektur VGG16 Untuk Klasifikasi Jenis Sampah," *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 3, no. 2, pp. 407–419, Sep. 2023, doi: 10.51454/decode.v3i2.331.
- [14] H. Pangestu Rahman and J. Indra, "Penerapan Convolutional Neural Network pada Timbangan Pintar Menggunakan ESP32-CAM," vol. 7, no. 1, pp. 283–291, 2023, doi: 10.30865/mib.v7i1.5469.
- [15] A. Kirana and H. Hikmayanti, "Pengenalan Pola Aksara Sunda dengan Metode Convolutional Neural Network," vol. 1, no. 2, 2020.
- [16] N. Fadlia and R. Kosasih, "KLASIFIKASI JENIS KENDARAAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN)," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 24, no. 3, pp. 207–215, 2021, doi: 10.35760/tr.2019.v24i3.2397.
- [17] D. Indarti, "Pengendalian Kualitas Produksi Lembaran Baja Melalui Klasifikasi Jenis Cacat Permukaan Menggunakan CNN," *Jurnal Rekayasa Sistem Industri*, vol. 12, no. 2, pp. 165–172, Oct. 2023, doi: 10.26593/jrsi.v12i2.5862.165-172.
- [18] Birawa Kaca Buana Gora, Nugroho Tegar Maulana, Muhamad Novan Aulia Zam Zami, Anan Nugroho, and Alfa Faridh Suni, "Deteksi Ketahanan Ban Sepeda Motor berdasarkan Indeks Beban Ban menggunakan CNN," *Jurnal Komputer dan Teknologi Informasi*, 2023, [Online]. Available: <http://e-journal.unipma.ac.id/index.php/doubleclick>
- [19] A. H. Nasrullah, "IMPLEMENTASI ALGORITMA DECISION TREE UNTUK KLASIFIKASI PRODUK LARIS," vol. 7, no. 2, 2021, [Online]. Available: <http://ejournal.fikom-unasman.ac.id>
- [20] H. S. Siska Febriani1, "ANALISIS DATA HASIL DIAGNOSA UNTUK KLASIFIKASI GANGGUAN KEPERIBADIAN MENGGUNAKAN ALGORITMA C4.5," *Jurnal Teknologi dan Sistem Informasi (JTSI)*, vol. 2, no. 4, pp. 89–95, 2021.