

# Rancang Bangun Aplikasi *Intelligent Visual Scanner* berbasis CNN untuk identifikasi cacat pada hasil pengelasan

Mochammad Karim Al Amin <sup>1</sup>, Ryan Yudha Adhitya <sup>2</sup>, Mohammad Miftachul Munir <sup>3</sup>, Mohammad Thoriq Wahyudi <sup>4</sup>, Dika Anggara <sup>5</sup>, Eka Cahya Septian <sup>6</sup>, Muhammad Ainul Yaqin <sup>7</sup>, Muhammad Ilham Safrudin <sup>8</sup>, Aulia Rahma Annisa <sup>9</sup>, Zindhu Maulana Ahmad Putra <sup>10</sup>

<sup>1,3,4,5</sup> Program Studi Teknik Pengelasan, Politeknik Perkapalan Negeri Surabaya, Surabaya, Indonesia

<sup>2,7,8</sup> Program Studi Teknik Otomasi, Politeknik Perkapalan Negeri Surabaya, Surabaya, Indonesia

<sup>9</sup> Program Studi Teknik Komputer, Institut Teknologi Telkom Surabaya, Surabaya, Indonesia

<sup>10</sup> Program Studi Teknik Kelistrikan Kapal, Politeknik Perkapalan Negeri Surabaya, Surabaya, Indonesia

<sup>6</sup> Chief Executive Officer, PT. Kintomo Engineering Group, Klaten, Indonesia

\* Korespondensi: [ranyudhaadhitya@ppns.ac.id](mailto:ranyudhaadhitya@ppns.ac.id)

**Abstrak:** Pengelasan merupakan salah satu sektor yang berperan penting dalam mendukung pembangunan infrastruktur yang semakin pesat. Namun dalam proses pengelasan banyak muncul kesalahan - kesalahan atau cacat yang terkadang luput dari inspeksi dan menyebabkan kerusakan pada benda kerja. Tujuan diadakannya penelitian ini adalah untuk merancang aplikasi *Intelligent Visual Scanner* dengan menggunakan metode CNN untuk mendeteksi kelayakan hasil pengelasan berdasarkan 3 kondisi, yaitu *Normal*, *Excess Reinforcement*, dan *Undercut*. Daerah yang akan dideteksi merupakan bagian dari hasil pengelasan pada plat besi dengan ketebalan 4mm. Pemotretan dilakukan menggunakan kamera ponsel beresolusi 48 MP. Gambar yang diambil berukuran 3024 x 3024 piksel, dengan terlebih dahulu diproses dengan konversi RGB ke *grayscale*. Kemudian gambar tersebut diperkecil (diubah ukurannya) ke skala yang lebih kecil yaitu 128 x 128 piksel untuk mempercepat proses training dan pada akhirnya proses testing menggunakan model CNN. Model CNN yang diusulkan pada penelitian ini menggunakan *optimizer* Adam. Untuk deteksi yang optimal, diperlukan dataset gambar sebanyak 300 gambar, dengan rincian 100 gambar normal, 100 gambar *Excess Reinforcement* dan 100 gambar *Undercut*. Data *split* training saat ini dibagi menjadi 75% data training dan 25% data validasi. Dari 300 dataset yang tersedia didapatkan rata-rata akurasi training sebesar 98% dengan rata-rata waktu training 1 menit 46 detik. Sedangkan untuk proses testing, akurasi deteksi pada *smartphone* 1 sebesar 84,8% dan *smartphone* 2 sebesar 72,7%. Pada saat proses testing dengan menggunakan *smartphone*, sistem lebih baik dalam mendeteksi hasil pengelasan dengan kondisi normal daripada kondisi cacat.

**Kata kunci:** Cacat; CNN; *Intelligent Visual Inspection Scanner*; Pengelasan.

## 1. Pendahuluan

Pengelasan merupakan salah satu metode untuk penyambungan antar benda kerja, namun pada proses pengelasan terkadang terdapat kecacatan pada hasil pengelasan yang mengakibatkan penurunan kekuatan [1]. Identifikasi hasil pengelasan perlu dilakukan untuk mengetahui kekuatan dari pengelasan tersebut. Metode identifikasi pengelasan terbagi menjadi 2 yaitu: *Destructive Testing* (DT) dan *Non Destructive Testing* (NDT) [2].

Keberadaan cacat las dapat menyebabkan kekuatan dan tingkat mutu hasil pengelasan berkurang [3]. Kecacatan yang sering terjadi adalah *Excess Reinforcement* dan *Undercut*. Tonjolan berlebih pada hasil pengelasan adalah ciri dari cacat las *Excess Reinforcement* [4]. *Excess Reinforcement* rawan terjadi

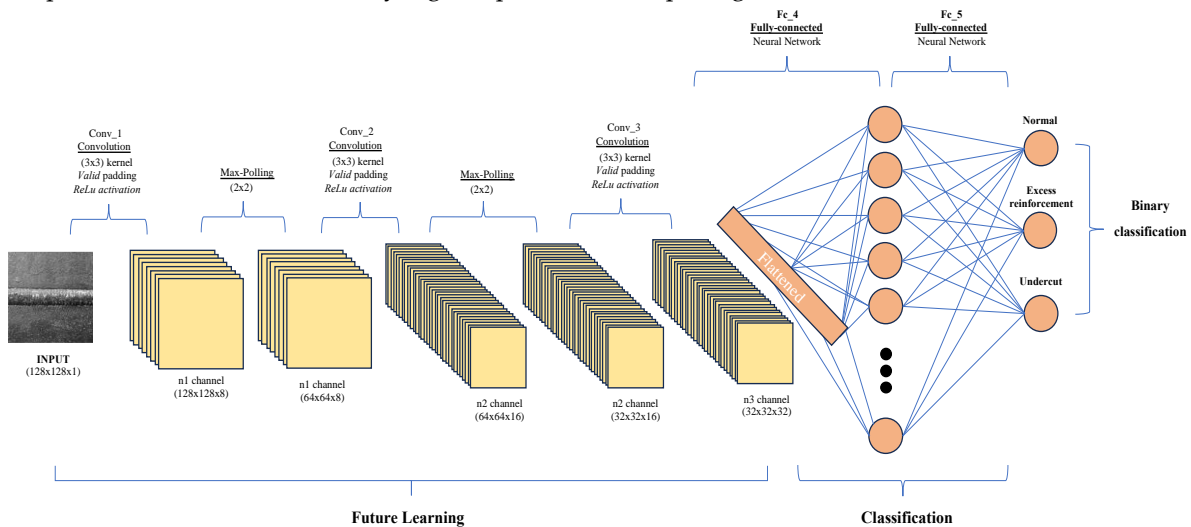
retak atau patah pada pangkalnya, karena terlalu tingginya kondisi *surface* atau permukaan pengelasan [5]. Hasil pengelasan dengan bentuk berupa repitisi kontur yang sama pada base metal merupakan ciri cacat las *Undercut* [6]. *Undercut* dapat menjadi titik potensial terjadinya retakan dan perambatan retakan karena kekuatan sambungan yang berkurang [7].

Karena keberadaan cacat las maka penelitian ini mengusulkan alat bantu inspeksi yang dinamakan *Intelligent Visual Inspection Scannner* menggunakan metode CNN untuk mengidentifikasi hasil pengelasan. Pada penelitian sebelumnya yang dilakukan oleh R. Miao pada tahun 2022 [8] mendapatkan nilai akurasi sebesar 96,94% dengan metode CNN dimana penelitian tersebut mendapatkan nilai akurasi yang lebih tinggi 10% daripada metode konvensional, sedangkan pada penelitian lain yang dilakukan oleh M. Karim Al Amin pada tahun 2023 [9] mendapatkan akurasi sebesar 100% dengan waktu puncak akurasi pada iterasi ke-2 dengan menggunakan *optimizer* ADAM. Maka dengan penggunaan *optimizer* ADAM pada metode CNN diharapkan mendapatkan akurasi yang baik untuk identifikasi pengelasan. Penelitian ini dilakukan untuk merancang aplikasi *Intelligence Visual Scanner* dengan menggunakan metode CNN untuk membantu pekerja melakukan identifikasi hasil pengelasan secara visual untuk kategori *Normal*, *Excess Reinforcement*, dan *Undercut*. Perbedaan mendasar dengan penelitian sebelumnya [9] adalah modifikasi dari proses arsitektur pada proses *feature maps* dengan pengulangan proses konvolusi hingga tiga kali dan proses maxpooling sebanyak dua kali. Modifikasi arsitektur ini dilakukan untuk mendapatkan informasi yang representatif dari masukan citra asli, sehingga akan didapatkan ciri khusus untuk matriks flattening yang dapat mempermudah dan mempercepat proses training. Modifikasi arsitektur ini menjadi nilai keterbaruan dari penelitian ini.


## 2. Metode

### A. Convolutional Neural Network

*Convolutional* merupakan bagian dari jaringan saraf tiruan yang dapat mengambil keputusan klasifikasi dengan melatihnya, serta mengimplementasikan jaringan multi-layer supaya dapat mengevaluasi gambar visual [10]. Karena kedalaman jaringan yang tinggi, CNN termasuk kedalam Deep Neural Network yang banyak diaplikasikan pada data citra [11]. Arsitektur *Convolutional Neural Network* dimulai dengan masukan citra digital dengan ukuran yang telah ditentukan, kemudian diteruskan ke lapisan konvolusional, lapisan penghubung keseluruhan (*fully connected*), dan menghasilkan output berupa label hasil klasifikasi [12] yang direpresentasikan pada gambar 1.



Gambar 1. Struktur *Convolutional Neural Network*



**Gambar 2.** (a) *Normal*; (b) *Excess Reinforcement*; dan (c) *Undercut*

## B. Spesifikasi *software* dan *hardware*

Pada penelitian ini untuk proses training dan running menggunakan software MATLAB R2023b dengan spesifikasi hardware Macbook M1 2020 dengan processor M1, RAM 8GB, SSD 246GB serta *Smartphone* Samsung seri A32, RAM 8GB, ROM 128GB, 48MP dan *Smartphone* Samsung seri A20, RAM 4GB, ROM 32GB, 13MP.

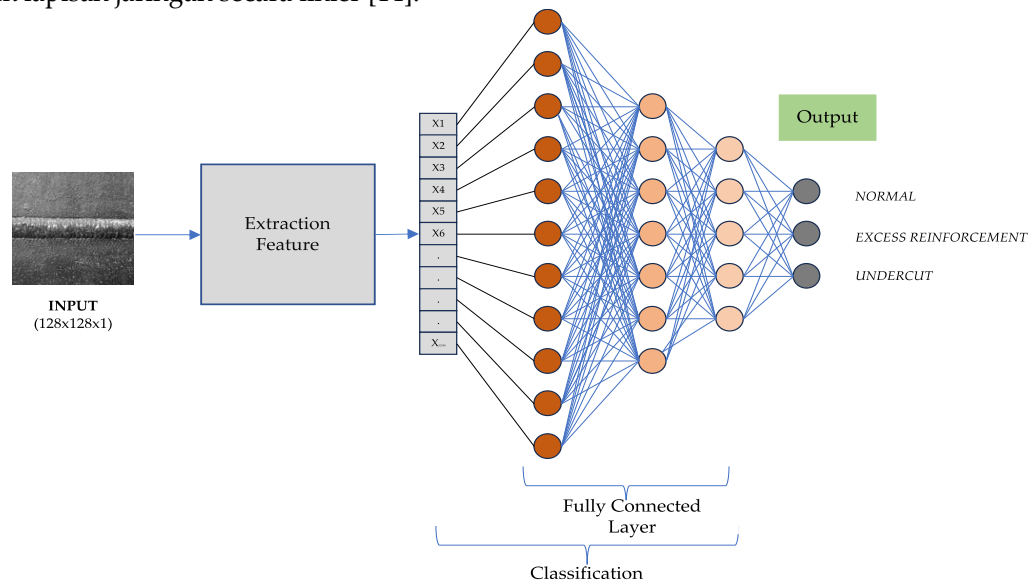
## C. Alur penelitian

### 1. Pengumpulan dataset


Pengumpulan dataset dilakukan dengan cara mengambil gambar hasil pengelasan menggunakan kamera *smartphone*. Data gambar yang sudah terkumpul diberi label berdasarkan kelas *Normal*, *Excess Reinforcement*, dan *Undercut* dengan jumlah masing-masing katagori berjumlah 100 gambar, sebagaimana yang ditunjukkan pada gambar 2.

### 2. Penyusunan arsitektur CNN

Untuk memperkaya model gambar, persiapan arsitektur dimulai dengan membuat parameter dan generator data termasuk pengubahan ukuran, rotasi gambar, *crop range*, *fill mode*, dan *range micro zoom* [13]. Pada penelitian ini menggunakan penyusunan model *Sequential*, yaitu mengurutkan dan menumpuk lapisan jaringan secara linier [14].



**Gambar 3.** Arsitektur *Convolutional Neural Network*



Gambar 4. Operasi convolutional

3. Proses data

Tahap proses data terdiri dari convolutional layer, activation function, subsampling atau polling layer, fully connected layer, dan softmax function.

1. Convolutional layer

Lapisan ini melakukan proses konvolusi antara filter dan gambar untuk menentukan tekstur/pola pada gambar 3 dan gambar 4 [15]. Dengan menggunakan operasi perkalian antar filter pada posisi atau titik yang sama sehingga menghasilkan ukuran dimensional feature map output yang lebih kecil. Penulisan persamaan perhitungan operasi konvolusi dapat dituliskan sebagai berikut (2.1):


$$TM[s]_{a,b} = \sum_c \sum_d N[a-c, b-d] F[m, n] + Rt \tag{1}$$

Keterangan:

- TM[s] : Feature map dari matriks ke-i
- a,b : Koordinat pixel pada input
- c,d : Koordinat pixel convolutional filters
- N : Input matriks
- T : Matriks filters

2. Activation function

Fungsi aktivasi dapat berupa sistem linear maupun nonlinear dengan mengukur fungsi penjumlahan dengan tujuan menentukan neuron aktif atau tidak [16]. Pelatihan data menggunakan fungsi aktivasi ReLu (Rectified Linear Unit) dapat mempercepat proses pembentukan data berdasarkan nilai terbesar (0, maksimum) yang dimasukkan.



Gambar 5. Struktural Pooling layers

### 3. *Subsampling* atau *polling layers*

Subsampling merupakan pengurangan jumlah elemen pada gambar yang dihasilkan dengan tujuan untuk mempercepat proses komputasi [17]. Pada penelitian ini menggunakan *max pooling* atau nilai terbesar dari tiap filter sebagai proses pooling layers seperti pada gambar 5.

### 4. *Fully connected layers*

Lapisan ini berfungsi untuk menghasilkan keluaran dengan mengambil seluruh masukan setiap neuron dari lapisan sebelumnya untuk melakukan operasi pada lapisan dengan masing-masing individu neuron [18].

### 5. *Softmax function*

Fungsi softmax sering digunakan pada lapisan keluaran jaringan saraf multilayer untuk menormalkan titik distribusi probabilitas dari hasil pengambilan vektor titik bernilai nyata yang telah diubah menjadi distribusi probabilitas agar interpretasi awal menjadi lebih mudah [19].

## 4. *Optimizer*

Proses optimasi penting untuk meningkatkan nilai akurasi dan juga meminimalkan overfitting pada saat pelatihan model. Dalam penelitian ini, *Adam optimizer* digunakan untuk mengoptimalkan model. *Adaptive Moment Estimation* atau ADAM merupakan metode gabungan antara RMSProp dan momentum, dua momen gradien yang dirata-ratakan dan juga mengambil gradien sebelumnya untuk mempercepat pembelajaran [20]. Penulisan persamaan perhitungan dirumuskan sebagai berikut (2.2):

$$\theta_t = \theta_t - 1 - \frac{\alpha}{\sqrt{v_t^{corrected} + \epsilon}} \cdot m_t^{corrected} \quad (2)$$

#### Keterangan

$\theta_t$  : Parameter yang diperbarui pada waktu t

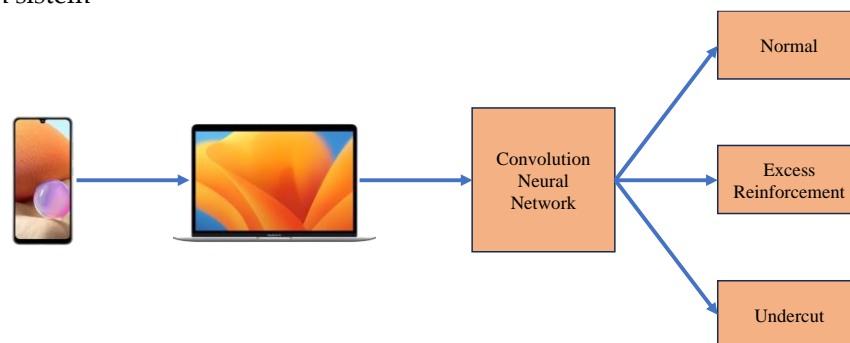
$\alpha$  : Laju pembelajaran

$Vt$  : Rata-rata gradien pada waktu iterasi

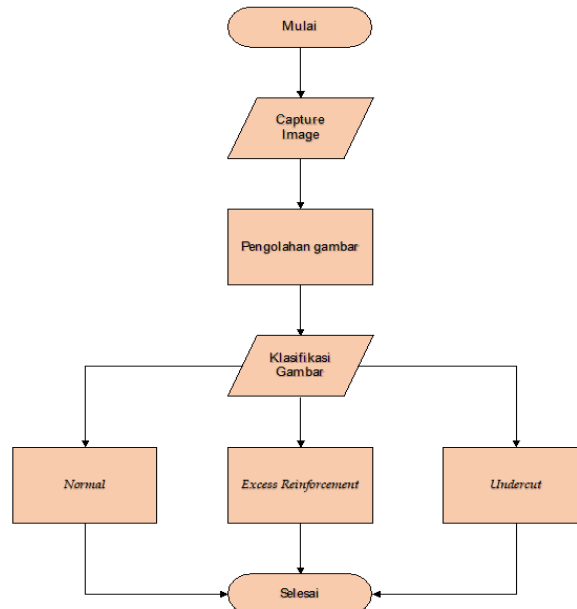
$\epsilon$  : Faktor kecil untuk mencegah pembagian oleh 0

$mt$  : Moment gradien pada waktu iterasi

## D. Perancangan sistem

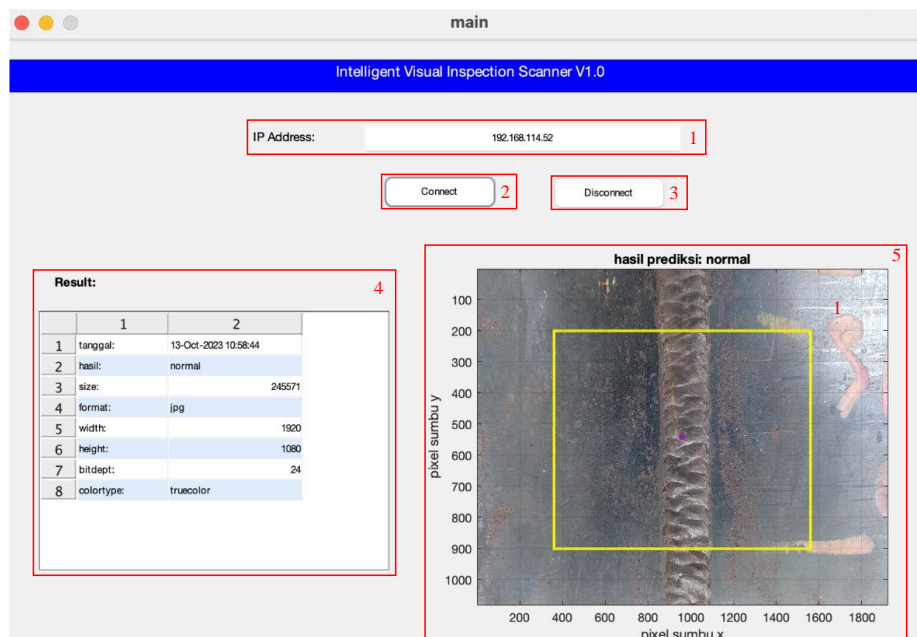


**Gambar 6.** Blok diagram rancang bangun aplikasi *Intelligent Visual Inspection Scanner*



Gambar 7. Flow chart sistem kerja aplikasi Intelligent Visual Scanner

Tahapan perancangan sistem dibuat dengan aplikasi MATLAB menggunakan Bahasa C, dimulai dari *capture image* menggunakan bantuan kamera smartphone dengan mengambil ip camera menggunakan aplikasi *ip webcam*, dapat diilustrasikan pada gambar 6 dan gambar 7. Gambar yang didapat diproses untuk mendapatkan hasil klasifikasi dari bobot hasil training. Pada program klasifikasi dilakukan pemrosesan gambar dan training untuk mendapatkan model bobot dari proses training, model tersebut digunakan sebagai bobot pada program utama untuk klasifikasi hasil pengelasan. Pada sistem utama terdapat program untuk tampilan aplikasi GUI sebagai interface pada aplikasi *Intelligent Visual Inspection Scanner* yang dapat ditunjukkan pada gambar 8.



Gambar 8. Tampilan aplikasi Intelligent Visual Inspection Scanner

Keterangan pada gambar 8 terdiri dari beberapa bagian:

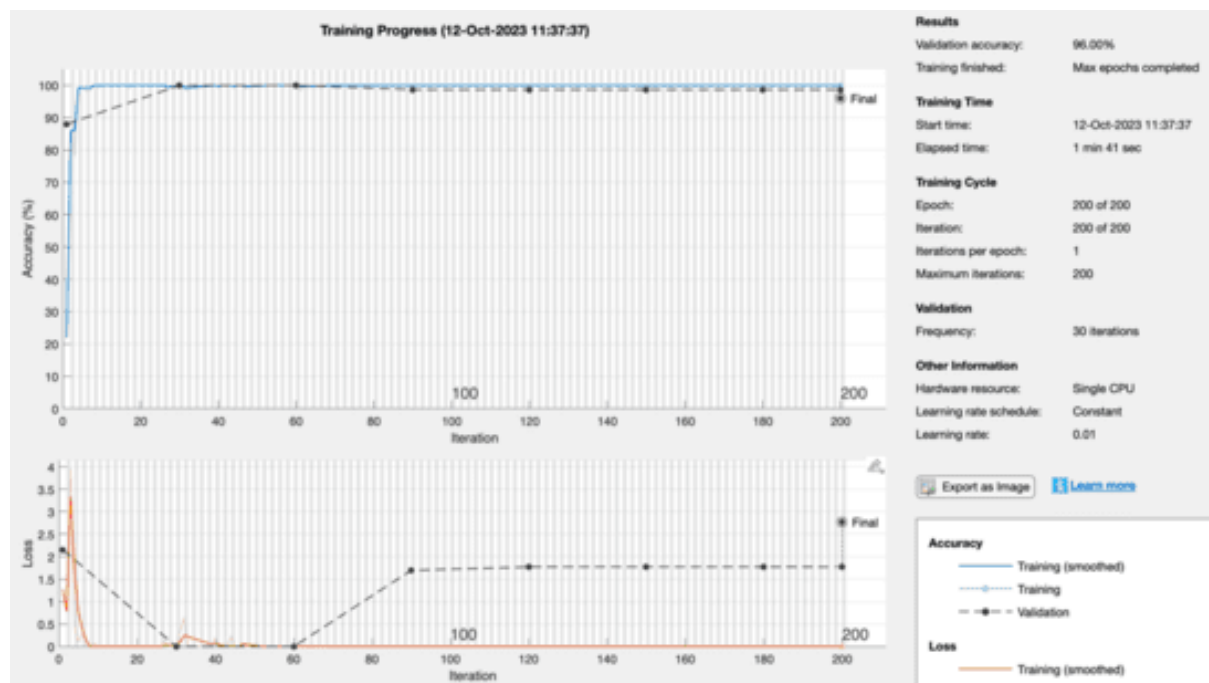
1. Setting IP Camera yang terdapat pada *smartphone*.
2. Tombol untuk memulai koneksi dengan kamera *smartphone*.
3. Tombol untuk menghentikan koneksi dengan kamera *smartphone*.
4. Tampilan data klasifikasi dalam bentuk tabel.
5. Tampilan kamera dan hasil klasifikasi.

### 3. Hasil

Hasil dari penelitian ini menunjukkan keberhasilan dalam mengidentifikasi hasil pengelasan secara *real-time*. Pengujian dilakukan pada plat *test piece* dengan menggunakan *smartphone* dan bantuan tripod untuk menjaga jarak kamera dengan object deteksi.

#### A. Hasil training dataset

Training dataset dilakukan menggunakan foto berjumlah 300 buah dengan rincian 100 foto normal, 100 foto *Excess reinforcement*, dan 100 foto *Undercut*. Pengujian training dilakukan untuk mengetahui akurasi dan lost dari dataset yang dilakukan, ditunjukkan pada gambar 9. Proses training CNN menghasilkan data sebagai berikut:



Gambar 9. Grafik akurasi dan training loss

**Tabel 1.** Akurasi training

| No. | Akurasi | Waktu |       |
|-----|---------|-------|-------|
|     |         | Menit | Detik |
| 1   | 96%     | 2     | 3     |
| 2   | 98%     | 1     | 58    |
| 3   | 98%     | 1     | 54    |
| 4   | 97%     | 1     | 57    |
| 5   | 98%     | 1     | 48    |
| 6   | 96%     | 1     | 52    |
| 7   | 99%     | 1     | 47    |
| 8   | 98%     | 1     | 47    |
| 9   | 97%     | 1     | 49    |
| 10  | 99%     | 1     | 41    |

Dengan menggunakan 300 dataset didapatkan rata-rata akurasi training sebesar 98% dengan rata-rata waktu training 1 menit 46 detik, secara keseluruhan dideskripsikan pada tabel 1. Proses training yang memakan waktu hingga lebih dari satu menit disebabkan oleh karakteristik input neuron pada *flattening layer* yang relatif banyak sehingga membutuhkan waktu komputasi proses yang tidak sedikit. Waktu pemrosesan training memiliki respon yang bervariasi karena kecepatan komputasi *personal computer* yang dinamis dengan hasil akurasi tiap sampling yang relative konstan dengan kisaran akurasi 96% hingga 99%. Waktu komputasi sedikit banyak juga dipengaruhi oleh metode propagasi balik ADAM *optimization* yang digunakan, proses kalkulasi metode ADAM memiliki matriks komputasi yang kompleks yang akan memakan ruang penyimpanan sementara atau *temporary space* pada komputer.

#### B. Hasil perbandingan dengan menggunakan dua buah *smartphone*

**Tabel 2.** Hasil *smartphone* Samsung A32

| No.            | Normal          | Excess Reinforcement | Undercut        |
|----------------|-----------------|----------------------|-----------------|
| 1              | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Berhasil</u> |
| 2              | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Berhasil</u> |
| 3              | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Tidak</u>    |
| 4              | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Berhasil</u> |
| 5              | <u>Berhasil</u> | <u>Tidak</u>         | <u>Berhasil</u> |
| 6              | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Berhasil</u> |
| 7              | <u>Berhasil</u> | <u>Tidak</u>         | <u>Berhasil</u> |
| 8              | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Berhasil</u> |
| 9              | <u>Tidak</u>    | <u>Berhasil</u>      | <u>Berhasil</u> |
| 10             | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Tidak</u>    |
| 11             | <u>Berhasil</u> | <u>Berhasil</u>      | <u>Berhasil</u> |
| <u>Akurasi</u> | 90.9%           | 81.8%                | 81.8%           |
| <u>Rerata</u>  |                 | 84.8%                |                 |

**Tabel 3.** Hasil *smartphone* Samsung A20

| No.     | Normal   | Excess Reinforcement | Undercut |
|---------|----------|----------------------|----------|
| 1       | Berhasil | Berhasil             | Tidak    |
| 2       | Berhasil | Berhasil             | Berhasil |
| 3       | Tidak    | Tidak                | Tidak    |
| 4       | Tidak    | Berhasil             | Berhasil |
| 5       | Berhasil | Berhasil             | Berhasil |
| 6       | Berhasil | Berhasil             | Berhasil |
| 7       | Berhasil | Berhasil             | Berhasil |
| 8       | Berhasil | Tidak                | Tidak    |
| 9       | Berhasil | Tidak                | Berhasil |
| 10      | Berhasil | Berhasil             | Berhasil |
| 11      | Berhasil | Berhasil             | Tidak    |
| Akurasi | 81.8%    | 72.7%                | 63.6%    |
| Rerata  |          | 72.7%                |          |

Dari tabel hasil akurasi didapatkan nilai akurasi pada *smartphone* 1 mendapatkan nilai akurasi pada kondisi normal sebesar 90.9%, pada kondisi cacat *Excess reinforcement* sebesar 81.8%, dan pada kondisi cacat *Undercut* sebesar 81.8% sedangkan pada *smartphone* 2 mendapatkan nilai akurasi pada kondisi normal sebesar 81.8%, pada kondisi cacat *Excess reinforcement* sebesar 72.7%, dan pada cacat undercut sebesar 63.6%. *Smartphone* 1 dalam hal ini adalah Samsung A23 memiliki kondisi akurasi rata – rata yang lebih baik dengan rata – rata akurasi 84.8% jika dibanding dengan *Smartphone* 2 atau Samsung A20 dimana akurasi rata – rata yang dihasilkan adalah 72.7%. Hal ini disebabkan kemampuan autofocus yang tidak dimiliki oleh semua *smartphone* dan faktor pencahayaan eksternal.

#### 4. Kesimpulan

Berdasarkan penelitian yang telah dilakukan maka dapat disimpulkan bahwa sistem berhasil melakukan identifikasi hasil pengelasan dengan menggunakan kamera *smartphone* untuk mendeteksi kelayakan hasil pengelasan berdasarkan 3 kondisi, yaitu *Normal*, *Excess Reinforcement*, dan *Undercut*. Ketepatan akurasi deteksi *smartphone* 1 sebesar 83,3% dan *smartphone* 2 sebesar 70%, sementara itu terdapat perbedaan akurasi antara kondisi normal dan kondisi cacat yang dapat diindikasikan bahwa *smartphone* 1 dan *smartphone* 2 lebih baik dalam mendeteksi hasil pengelasan dengan kondisi normal daripada kondisi cacat. Tampilan GUI mampu menampilkan parameter tanggal secara *real-time* dengan benar dan juga menampilkan parameter objek yang masuk didalam bounding box pada hasil tangkapan kamera seperti *size*, *format width*, *height*, *bitdept*, *colortype*. Pada sistem ini tingkat keberhasilan dipengaruhi oleh spesifikasi kamera dan kemampuan sebuah kamera untuk memfokuskan ke sebuah objek hasil pengelasan secara dekat. Hal ini menunjukkan bahwa perangkat keras (kamera) memiliki peran yang penting akurasi deteksi.

## Referensi

1. H. Pan, Z. Pang, Y. Wang, Y. Wang, and L. Chen, "A New Image Recognition and Classification Method Combining Transfer Learning Algorithm and MobileNet Model for Welding Defects," *IEEE Access*, vol. 8, pp. 119951–119960, 2020, doi: 10.1109/ACCESS.2020.3005450.
2. A. Rizal Lucky Pradana, S. Khumaidi, M. T. St, R. Andiana, and S. St, "Identifikasi Penyebab Cacat Pada Hasil Pengelasan Dengan Image Processing Menggunakan Metode YOLO", [Online]. Available: <https://journal.trunojoyo.ac.id/triac>
3. F. Kurniadi, F. Handoko, T. Priyasmanu, and P. Studi Teknik Industri S-, "ANALISIS WELDING DEFECT RATE DAN PENANGANANNYA DENGAN METODE SIX SIGMA DAN FMEA (STUDI KASUS: PT. MEINDO ELANG INDAH, MUARA JAWA, KUTAI KARTANEGARA, KALTIM)," *Jurnal Mahasiswa Teknik Industri*, vol. 5, no. 1, 2022.
4. N. V. R. Maganti and R. R. Potturi, "Investigation on Mechanical and Machinability Properties of Aluminium Metal Matrix Composite Reinforced with Titanium Oxide (TiO<sub>2</sub>) and Graphite (Gr) Particles," *Trends in Sciences*, vol. 20, no. 11, p. 5682, Aug. 2023, doi: 10.48048/tis.2023.5682.
5. M. Bin Afan, B. Rahim Jurusan Teknik Mesin, F. Teknik, and U. Negeri Padang Jl Hamka, "Pengaruh Suhu Penyimpanan Elektroda Low Hydrogen E7016 terhadap Hasil Uji Tekuk Sambungan Las Pelat Baja Karbon SS400," 2020. [Online]. Available: <https://jurnal.polines.ac.id/index.php/rekayasa>
6. A. Khatammi and A. W. Rizqi, "Analisis Kecacatan Produk Pada Hasil Pengelasan dengan Metode Failure Mode Effect Analysis," *Serambi Engineering*, vol. VII, no. 2, 2022.
7. A. O. Igbinke, "FUPRE Journal of Scientific and Industrial Research Estimation of Undercuts in Mild Steel Weldment using Artificial Neural Network," *Journal Research Article / Review Article FUPRE JOURNAL*, vol. 7, no. 1, pp. 138–147, 2023, [Online]. Available: <http://fupre.edu.ng/journal>
8. R. Miao *et al.*, "Real-time defect identification of narrow overlap welds and application based on convolutional neural networks," *J Manuf Syst*, vol. 62, pp. 800–810, Jan. 2022, doi: 10.1016/j.jmsy.2021.01.012.
9. M. Karim Al Amin *et al.*, "Analysis of Optimizer Effects on CNN Model for Defect Identification in Welding Results of A 106 Grade B Carbon Steel Pipe.", ICEEI 2023.
10. M. Defriani and I. J. Jaelani, "Recognition of Regional Traditional House in Indonesia Using Convolutional Neural Network (CNN) Method," *Journal of Computer Networks, Architecture and High Performance Computing*, vol. 4, no. 2, pp. 104–115, Jul. 2022, doi: 10.47709/cnahpc.v4i2.1562.
11. P. Adi Nugroho, I. Fenriana, and R. Arijanto, "IMPLEMENTASI DEEP LEARNING MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK ( CNN ) PADA EKSPRESI MANUSIA," *JURNAL ALGOR*, vol. 2, no. 1, 2020, [Online]. Available: <https://jurnal.buddhidharma.ac.id/index.php/algor/index>
12. M. D. Pramita, B. Kurniawan, and N. P. Utama, "Mask Wearing Classification using CNN," in *2020 7th International Conference on Advanced Informatics: Concepts, Theory and Applications, ICAICTA 2020*, Institute of Electrical and Electronics Engineers Inc., Sep. 2020. doi: 10.1109/ICAICTA49861.2020.9429029.
13. A. F. Anavyanto, M. Maimunah, M. R. A. Yudianto, and P. Sukmasetya, "EfficientNetV2M for Image Classification of Tomato Leaf Diseases," *PIKSEL : Penelitian Ilmu Komputer Sistem Embedded and Logic*, vol. 11, no. 1, pp. 55–76, Mar. 2023, doi: 10.33558/piksel.v11i1.5925.
14. G. Xie, A. Shanguan, R. Fei, W. Ji, W. Ma, and X. Hei, "Motion trajectory prediction based on a CNN-LSTM sequential model," *Science China Information Sciences*, vol. 63, no. 11, Nov. 2020, doi: 10.1007/s11432-019-2761-y.
15. IEEE Communications Society. Indonesia Chapter., Universitas Telkom., and Institute of Electrical and Electronics Engineers, *Proceedings, the 2020 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology : July 7-8, 2020, Bali, Indonesia*.
16. T. Purwaningsih, T. Nurhikmat, and P. B. Utami, "Image Classification of Golek Puppet Images using Convolutional Neural Networks Algorithm," *Int. J. Advance Soft Compu. Appl*, vol. 11, no. 1, 2019.
17. STMIK AKAKOM Yogyakarta, Institute of Electrical and Electronics Engineers. Indonesia Section, and Institute of Electrical and Electronics Engineers, *2nd ISRITI 2019 proceeding : the 2nd International Seminar on Research of Information Technology and Intelligent Systems 2019 : "The future & challenges of extended intelligence" : Yogyakarta, Indonesia, 05-06 December 2019*.
18. S. Bhattacharyya, RCC Institute of Information Technology. Department of Information Technology, and Institute of Electrical and Electronics Engineers, *Proceedings, 2018 Fourth IEEE International Conference on*

*Research in Computational Intelligence and Communication Networks (ICRCICN) : 22nd and 23rd November, 2018, Kolkata, India.*

19. S. Kanungo, "ANALYSIS OF IMAGE CLASSIFICATION DEEP LEARNING ALGORITHM."
20. M. H. Saleem, J. Potgieter, and K. M. Arif, "Plant disease classification: A comparative evaluation of convolutional neural networks and deep learning optimizers," *Plants*, vol. 9, no. 10, pp. 1–17, Oct. 2020, doi: 10.3390/plants9101319.



© 2019 oleh penulis. Dikirim untuk kemungkinan publikasi akses terbuka di bawah syarat dan ketentuan lisensi Creative Commons Attribution (CC BY) (<http://creativecommons.org/licenses/by/4.0/>).