

Sistem Pendeteksi Hasil Pengelasan dengan *Image Processing* Berdasarkan Klasifikasi Metode *Principal Component Analysis* dan *Neural Network*

Sherlyna Anggraini Putri¹, Mat Syai'in¹, Ryan Yudha Adhitya¹

¹²³Program Studi Teknik Otomasi, Jurusan Teknik Kelistrikan Kapal

Politeknik Perkapalan Negeri Surabaya

Jalan Teknik Kimia, Kampus ITS Sukolilo, Surabaya 60111

E-mail : sherlynaanggraini@student.ppns.ac.id

Abstrak

Dalam proses pengujian suatu sambungan las, inspeksi visual merupakan langkah awal untuk menentukan kualitas sambungan las yang masih menggunakan penglihatan manusia untuk mengetahui jenis kecacatan pada hasil pengelasan dan memutuskan proses pengujian selanjutnya, sehingga hasil pengujian masih bersifat subjektif. Oleh karena itu, diperlukan pengembangan inovasi dalam melakukan proses visual inspection melalui *image processing* dengan menggunakan metode 2D *Principal Component Analysis* dan metode *Deep Learning Neural Network* model *Backpropagation* untuk klasifikasi kecacatan las dan memberikan keputusan kelayakan benda uji. Penelitian ini menggunakan sepuluh *input* citra yang diambil secara *real-time* dari kamera berdasarkan komposisi *data training* dan *testing* dengan persentase 80% dan 20%. Kemudian untuk ekstraksi ciri menggunakan 2D *Principal Component Analysis* yang selanjutnya akan dilakukan klasifikasi kecacatan hasil pengelasan dengan *Deep Learning Neural Network*. Model *Backpropagation Neural Network* terbaik yang digunakan memiliki arsitektur *input layer* sebanyak 100 *neuron*, *hidden layer* 1 sebanyak 18 *neuron*, *hidden layer* 2 sebanyak 12 *neuron* dan *output layer* sebanyak 6 *neuron*. Hasil prediksi dari klasifikasi cacat las menggunakan metode *Neural Network* model *Backpropagation* memiliki nilai presentase keberhasilan pengujian sistem sebesar 88,66% dapat menunjukkan bahwa model memiliki tingkat keakuratan yang baik.

Kata Kunci : *Image Processing*, Kecacatan Las, *Neural Network*, 2D-*Principal Component Analysis*

1. PENDAHULUAN

Kapal memiliki ukuran yang lebih besar dari struktur transportasi biasa. Oleh karena itu, proses dalam perancangan dan pembuatannya lebih kompleks. Pada proses pembuatan kapal, sekitar 60% dari proses tersebut adalah proses pengelasan yang melibatkan deformasi las [1]. Pengelasan merupakan teknik penyambungan material logam dengan cara peleburan menggunakan panas. Hasil pengelasan harus diuji untuk mengetahui seberapa besar kekuatan dari sambungan las tersebut dan kompetensi welder sehingga dapat melanjutkan ke proses pengelasan skala besar.

Visual Inspection pada pengelasan merupakan suatu metode untuk menentukan kualitas mutu atau kondisi hasil pengelasan berdasarkan spesifikasi dan standart yang telah ditentukan. Proses inspeksi visual dilakukan pada hasil pengelasan untuk mengetahui kecacatan, kelainan maupun ketidak-sesuaian permukaan pada sambungan las. Menurut S. Widharto [2], terdapat 2 metode untuk melakukan pengujian hasil pengelasan, yaitu *Destructive Test* (DT) dan *Non-Destructive*

Tests (NDT). Metode DT merupakan metode inspeksi hasil pengelasan dengan merusak material saat pengujian. Metode DT bertujuan untuk mengetahui *strength* dari suatu hasil pengelasan dengan menggunakan pembebanan. Pengujian *Destruction Test* dibagi menjadi beberapa kategori yaitu *Bending Test*, *Tensile Test*, *Hardness Test*, *Impact Test*. Sedangkan, *Non-Destructive Test* merupakan metode inspeksi hasil pengelasan tanpa merusak material saat pengujian. Menurut Agus Khumaidi (Khumaidi, 2017), pengujian metode NDT dibagi menjadi beberapa kategori yaitu *Visual Inspection* (VT), *Liquid Penetrant Testing* (LT), *Ultrasonic Testing* (UT), *Phased Array Ultrasonics* (PA), *Magnetic Particle Testing* (MT), *Eddy Current Testing* (ET), *Acoustic Emission Testing* (AET), *Time of Flight Diffraction* (TOFD), *Radiographic Testing* (RT).

Pada inspeksi visual secara manual hanya menggunakan kekuatan dan ketajaman mata untuk melihat kecacatan pada permukaan sambungan las. Oleh karena itu, diperlukan


persyaratan yang ketat bagi *welding inspector*, seperti kesehatan mata, pengetahuan tentang kecacatan pada permukaan las dan pengalaman mengenai teknologi las yang luas dan mendalam. Hal ini sangat penting mengingat inspeksi visual sangat menentukan dapat diterima atau ditolak suatu sambungan las pada benda kerja secara langsung dan menentukan tindak lanjut untuk mengetahui kecacatan internal pada proses NDT.

Berdasarkan pembahasan diatas, penulis memiliki inovasi sebuah sistem pendeteksi hasil pengelasan dengan *Image Processing* berdasarkan klasifikasi metode *Principal Component Analysis* 2D (PCA-2D) dan *Deep Learning Neural Network*. Metode ini mampu menganalisa suatu kecacatan pada sambungan las berdasarkan hasil *Grayscale* dari proses *pre-processing* pada *Image Processing* yang akan diekstraksi pada metode 2D-PCA dan sebagai *input training* pada *Neural Network* untuk klasifikasi kecacatan pengelasan sehingga dapat memberikan keputusan kelayakan dari sambungan las. *Input* dari penelitian ini menggunakan kamera secara langsung sehingga didapatkan keputusan kelayakan suatu sambungan las secara *real-time* dengan besar persentase kecacatan pada sambungan las, serta keputusan kelayakan hasil pengelasan.

Klasifikasi hasil pengelasan sebagai vektor *output* yang digunakan sebagai acuan adalah normal, *over spatter*, *porosity*, *undercutting*, *underfill* dan *overlap*. Pada saat pengujian, benda uji yang digunakan berbentuk plat jenis sambungan temu (*butt joint*) dengan dimensi maksimum panjang dan lebar sebesar 30cm.

2. METODE

Sistematika alur penelitian ini direpresentasikan pada **Gambar 2.1** berikut:



Gambar 2.1 Flowchart Alur Penelitian

Berdasarkan *flowchart* alur penelitian pada **Gambar 2.1**, penjelasan secara rinci dijelaskan pada sub-bab berikut:

2.1 Studi Literatur

Pada tahap ini, studi literatur meliputi mempelajari, memahami dan menganalisa materi yang terkait dengan penelitian ini, seperti pengetahuan tentang kecacatan pengelasan [3], Algoritma *Principal Component Analysis* (PCA) [4], [5], tahapan proses analisa citra menggunakan metode 2DPCA [6], proses pembelajaran metode *Neural Network* [7], [8], *Backpropagation Neural Network* [9], [10] dan algoritmanya [11], serta beberapa sumber penelitian sebelumnya yang *relevant* dengan penelitian ini seperti [12], [13], [14], [15].

2.2 Analisa Kebutuhan


Pada tahap ini, dilakukan analisa kebutuhan sistem. Analisa kebutuhan sistem ini meliputi pendataan komponen-komponen pembangun sistem yang akan dibuat. Komponen tersebut tertera pada **Tabel 2.1** berikut.

Tabel 2.1 Komponen yang Digunakan

Hardware	Software
Webcam PC Motor DC Arduino Uno Driver Motor BTS7960 Module Baterai Li-Po	Matlab

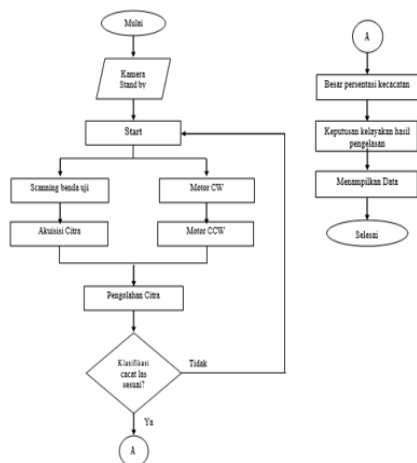
2.3 Perancangan Sistem

Perancangan sistem secara keseluruhan terdiri dari *input*, *process*, dan *output*. *Input* pada sistem berupa *webcam* yang digunakan untuk mengambil citra yang kemudian akan diproses pada PC, hasil proses tersebut akan digunakan sebagai acuan dalam menggerakkan Motor DC yang dikendalikan oleh Arduino. Selain itu, hasil tersebut ditampilkan pada GUI Matlab. **Gambar 2.2** merupakan diagram blok keseluruhan sistem ini.



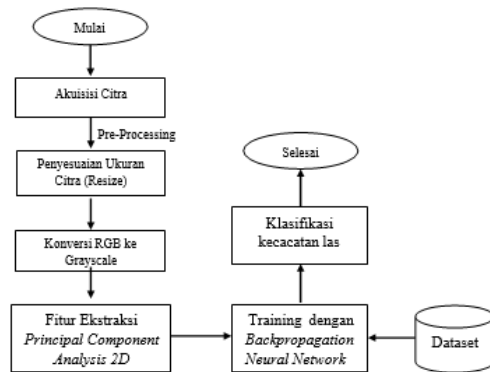
Gambar 2.2 Diagram Blok Sistem

Alur kerja dari sistem ini direpresentasikan dalam bentuk *flowchart* **Gambar 2.3** berikut.



Gambar 2.3 Alur Kerja Sistem


Proses pengolahan citra pada sistem ini direpresentasikan pada diagram blok **Gambar 2.4** berikut.



Gambar 2.4 Diagram Rancangan Pengolahan Citra

2.4 Dataset


Dataset berfungsi untuk keperluan *training*, pada penelitian ini proporsi data *training* yang digunakan adalah 80% dari total data gambar, dan untuk keperluan pengujian atau validasi diambil sebesar 20% dari total data gambar. Total data gambar secara keseluruhan adalah 180 data dengan rincian data citra untuk kelas *Normal* sebanyak 30 data, data citra untuk kelas *over spatter* sebanyak 30 data, data citra untuk kelas *porosity* sebanyak 30 data, data citra untuk kelas *undercut* sejumlah 30 data dan terakhir untuk kelas *underfill* sejumlah 30 data. Semua citra berukuran 100 x 100 piksel, penentuan proporsi data untuk keperluan *training* dan validasi dilakukan secara acak atau random. Pada **Gambar 2.5** merupakan *sample dataset* pada masing-



Gambar 2.5 Dataset

2.5 Arsitektur Jaringan


Arsitektur jaringan meliputi proses pengenalan citra hingga proses klasifikasi citra menggunakan *Neural Network*. **Gambar 2.6** merupakan arsitektur jaringan pengolahan citra pada penelitian ini.



Gambar 2.6 Arsitektur Jaringan

2.6 Rancangan Prototype

Pada **Gambar 2.7** menunjukkan desain tampilan dari *prototype* yang telah terpasang kamera pada bagian atas dari meja uji sehingga dapat mencangkup benda uji. Rancangan *prototype* ini didesain untuk memaksimalkan proses akuisisi citra pada benda uji, agar mendapatkan hasil klasifikasi dengan tepat dan besar persentase dari kecacatan las. Sehingga sistem dapat berjalan dengan baik.



Gambar 2.7 Rancangan Prototype

2.7 Uji Coba

Pada tahap ini dilakukan pengujian produk dengan mengoperasikan keseluruhan sistem. Pengujian ini menggunakan benda uji berbentuk plat jenis sambungan temu (*butt*

joint) dengan dimensi maksimum panjang dan lebar sebesar 30cm dan posisi peletakan benda uji pada *prototype* harus sesuai dengan lokasi yang telah ditetapkan

2.8 Analisis Data

Pada tahap ini dilakukan analisis data dari data-data yang telah diperoleh pada tahap uji coba. Hasil analisa data pada tahap ini akan digunakan untuk menarik kesimpulan dari penelitian ini.

2.9 Pembuatan Laporan Akhir

Penyusunan laporan akhir bertujuan sebagai bentuk tanggung jawab dan otentik atas terselenggaranya penelitian ini.

3. HASIL DAN PEMBAHASAN

3.1 Perancangan Hardware

Perancangan *Hardware* pada penelitian ini meliputi perancangan mekanik. Peletakan sensor dan aktuator pada perancangan mekanik ini telah disesuaikan dengan kebutuhan penelitian ini. **Gambar 3.1** merupakan tampak keseluruhan *prototype* sistem.









Gambar 3.1 Penampakan *Hardware*

3.2 Data Testing Metode Backpropagation Neural Network

Parameter *Output* pada proses testing pada masing-masing sampel berupa biner. Berikut ini adalah parameter *output* pada masing-masing sampel seperti yang terlihat pada **Tabel 3.1** berikut ini.

Tabel 3.1 Parameter *Output Testing Backpropagation Neural Network*

No.	Citra Latih	Output Testing BPNN	Keterangan
1.		1 0 0 0 0 0	Normal

2.		0 1 0 0 0 0	Over Spatter
3.		0 0 1 0 0 0	Over Lap
4.		0 0 0 1 0 0	Porosity
5.		0 0 0 0 1 0	Undercut
6.		0 0 0 0 0 1	Underfill

3.3 Hasil Testing Metode Backpropagation Neural Network

Pada bagian sebelumnya, telah dijelaskan mengenai pencarian arsitektur *backpropagation Neural Network* yang memiliki akurasi yang bagus. Selanjutnya perbandingan hasil prediksi dilakukan dengan hasil testing dari *Neural Network*. Selanjutnya adalah proses testing dari metode *Neural Network*. Variabel data citra *training* dan data citra *testing* yang digunakan pada tugas akhir ini dapat dilihat pada **Tabel 3.2** Parameter *Input Dataset*.

Tabel 3.2 Parameter *Input Dataset*

	Data Training	Data Testing
Jumlah Data	144	36
Resolusi	100 x 100	100 x 100
Channel Warna	Grayscale	Grayscale






Data Testing merupakan data yang akan digunakan sebagai proses validasi pada pengujian tugas akhir ini, dengan proporsi yang telah dijelaskan sebelumnya bahwa data testing memiliki proporsi sebesar 20% dari data citra keseluruhan (*dataset*). Sehingga

terdapat 36 data citra testing yang terbagi menjadi 6 sampel dengan tiap-tiap sampel terdapat 6 data citra uji. Berikut adalah hasil testing metode *Backpropagation Neural Network*.

3.4 Pengujian pada Hasil Pengelasan Normal

Pada pengujian hasil pengelasan Normal dari total 6 kali percobaan yang telah dilakukan seluruh citra *testing* dapat dikenali oleh metode ini, dengan besar persentase yaitu 100%, seperti yang terlihat pada **Tabel 3.3** berikut ini.

Tabel 3.3 Data Hasil Pengujian pada Hasil Pengelasan Normal






No.	Citra Uji	Output BPNN	Keterangan
1.		1 0 0 0 0 0	Benar
2.		1 0 0 0 0 0	Benar
3.		1 0 0 0 0 0	Benar
4.		1 0 0 0 0 0	Benar
5.		1 0 0 0 0 0	Benar

3.5 Pengujian pada Hasil Pengelasan Over Spatter

Pada pengujian hasil pengelasan Over Spatter dari total 6 kali percobaan terdapat 1 citra *testing* yang gagal dikenali oleh metode ini, dengan besar persentase yaitu 83%, seperti yang diperhatikan pada **Tabel 3.4** berikut ini.

Tabel 3.4 Data Hasil Pengujian pada Hasil Pengelasan Over Spatter





No.	Citra Uji	Output BPNN	Keterangan
-----	-----------	-------------	------------


1.		0 1 0 0 0 0	Benar
2.		1 0 0 0 0 0	Salah
3.		0 1 0 0 0 0	Benar
4.		0 1 0 0 0 0	Benar
5.		0 1 0 0 0 0	Benar

3.6 Pengujian pada Hasil Pengelasan Over Lap

Pada pengujian hasil pengelasan Over Lap dari total 6 kali percobaan terdapat 2 citra *testing* yang gagal dikenali oleh metode ini, dengan besar persentase yaitu 66%, seperti yang diperhatikan pada **Tabel 3.5** berikut ini.

Tabel 3.5 Data Hasil Pengujian pada Hasil Pengelasan Over Lap

No.	Citra Uji	Output BPNN	Keterangan
1.		0 0 1 0 0 0	Benar
2.		0 0 1 0 0 0	Benar
3.		0 0 0 0 1 0	Salah
4.		0 0 1 0 0 0	Benar






5.		1 0 0 0 0 0	Salah
----	---	----------------	-------

3.7 Pengujian pada Hasil Pengelasan

Porosity

Pada pengujian hasil pengelasan Porosity dari total 6 kali percobaan yang telah dilakukan seluruh citra testing dapat dikenali oleh metode ini, dengan besar persentase yaitu 100%, seperti yang terlihat pada **Tabel 3.6** berikut ini.

Tabel 3.6 Data Hasil Pengujian pada Hasil Pengelasan *Porosity*

No.	Citra Uji	Output BPNN	Keterangan
1.		0 0 0 1 0 0	Benar
2.		0 0 0 1 0 0	Benar
3.		0 0 0 1 0 0	Benar
4.		0 0 0 1 0 0	Benar
5.		0 0 0 1 0 0	Benar






3.8 Pengujian pada Hasil Pengelasan

Undercut

Pada pengujian hasil pengelasan Undercut dari total 6 kali percobaan terdapat 1 citra *testing* yang gagal dikenali oleh metode ini, dengan besar persentase yaitu 83%, seperti yang diperhatikan pada **Tabel 3.7** berikut ini.

Tabel 3.7 Data Pengujian pada Hasil Pengelasan *Undercut*

No.	Citra Uji	Output BPNN	Keterangan
-----	-----------	-------------	------------





1.		0 0 0 0 1 0	Benar
2.		0 0 0 0 1 0	Benar
3.		0 0 0 0 0 1	Salah
4.		0 0 0 0 1 0	Benar
5.		0 0 0 0 1 0	Benar

3.9 Pengujian pada Hasil Pengelasan

Underfill

Pada pengujian hasil pengelasan Underfill dari total 6 kali percobaan yang telah dilakukan seluruh citra testing dapat dikenali oleh metode ini, dengan besar persentase yaitu 100%, seperti yang terlihat pada **Tabel 3.8** berikut ini.

Tabel 3.8 Data Hasil Pengujian pada Hasil Pengelasan *Underfill*

No	Citra Uji	Output BPNN	Keterangan
1.		0 0 0 0 0 1	Benar
2.		0 0 0 0 0 1	Benar
3.		0 0 0 0 0 1	Benar
4.		0 0 0 0 0 1	Benar

5.		0 0 0 0 0 1	Benar
----	---	----------------	-------

4. PENUTUP

4.1 Kesimpulan

Berdasarkan hasil yang telah didapatkan pada analisa dan pengujian sistem yang telah dibuat, maka dapat disimpulkan bahwa :

1. Klasifikasi Hasil Pengelasan menggunakan *image processing* dengan klasifikasi metode 2D PCA dan *Deep Learning Neural Network* dilihat dari besar akurasi yang dihasilkan oleh *Neural Network model Backpropagation* dinilai mampu dilakukan dengan arsitektur 100 – 18 – 12 – 6 yaitu model terdiri dari 100 *neuron* pada *input layer*, 18 *neuron* pada *hidden layer 1*, 12 *neuron* pada *hidden layer 2* dan 6 *neuron* pada *output layer* dengan rata-rata akurasi keberhasilan sebesar 88,66%.
2. Penentuan besar persentase kecacatan hasil pengelasan dengan menggunakan *image* yang berdasarkan nilai *output* dari *Backpropagation Neural Network* pada sampel normal yaitu 1 0 0 0 0 0. *Input*-an citra akan dikurangi dengan sampel normal pada proses pengujian, sehingga menghasilkan besar persentase kecacatan hasil pengelasan.
3. Pemberian keputusan pada hasil pengelasan diputuskan atas dasar besar persentase kecacatan hasil pengelasan dengan *range* kurang dari sama dengan 30%, hasil pengelasan tersebut “*accepted*”. Sedangkan persentase kecacatan las lebih dari 30%, hasil pengelasan tersebut “*Rejected*”.

4.2 Saran

Berdasarkan percobaan yang telah dilakukan terdapat beberapa saran untuk melanjutkan dan memperbaiki kekurangan yang ada pada tugas akhir ini, yaitu :

1. Memperhatikan kondisi cahaya sekitar karena sangat mempengaruhi hasil pembacaan webcam dan mempengaruhi hasil *output*.
2. Menggunakan *webcam* dengan resolusi yang lebih baik agar mendapatkan hasil pembacaan *webcam* yang lebih tajam untuk memudahkan sistem meningkatkan akurasi.
3. Memperbanyak varian dan jumlah *dataset* yang digunakan untuk *training* pada

metode *Backpropagation Neural Network* agar mendapatkan hasil dengan tingkat akurasi yang lebih tinggi.

4. Dalam mengambil *dataset* perlu diperhatikan perbedaan antar *welding defect* yang digunakan untuk citra latih. Hal ini untuk meminimalisir kesalahan dalam prediksi baik pada proses *training* maupun *testing*.
5. Guna meningkatkan tingkat akurasi prediksi klasifikasi yang dihasilkan oleh *model Backpropagation*, dapat dilakukan *training* ulang untuk mencari arsitektur *Neural Network* yang lebih tinggi akurasinya, sehingga mendapatkan nilai akurasi yang baik saat *testing*.

5. DAFTAR PUSTAKA

- [1] Y. Kim, J. Kim, and S. Kang, “A study on welding deformation prediction for ship blocks using the equivalent strain method based on inherent strain,” *Appl. Sci.*, vol. 9, no. 22, 2019, doi: 10.3390/app9224906.
- [2] S. Widharto, *Welding Inspection*. Jakarta: Mitra Wacana Media, 2013.
- [3] J. Primo, “Welding Inspection Qualifications & Testing Procedures,” vol. 415, 2012.
- [4] N. Fadillah, “Hand Human Recognition Berdasarkan Geometri Telapak,” vol. 10, no. 2, pp. 771–786, 2019.
- [5] A. R. Syakhala, D. Puspitaningrum, and E. P. Purwandari, “Perbandingan Metode Principal Component Analysis (PCA) dengan Metode Hidden Markov Model (HMM) dalam Pengenalan Identitas,” *J. Inform.*, vol. 3, no. 2, pp. 68–81, 2015, [Online]. Available: <https://ejournal.unib.ac.id/index.php/rekursif/issue/archive>.
- [6] Indra, “Sistem Pengenalan Wajah Dengan Metode 2D-PCA,” *J. Pendidik. Teknol. Komun. Terap.*, no. July 2012, p. 138, 2012.
- [7] S. J. Russell and P. Norvig, *Artificial intelligence: A modern approach*, Second Edi. United State of America: Prentice Hall, 2003.
- [8] M. Agustin and T. Prahasto, “Penggunaan Jaringan Syaraf Tiruan Backpropagation Untuk Seleksi Penerimaan Mahasiswa Baru Pada Jurusan Teknik Komputer,” vol. 02, pp.

89–97, 2012.

- [9] R. N. Fadhilah and R. V. H. Ginardi, "Penentuan Harga Dengan Metode Back Propagation pada Aplikasi E-Commerce CariKos Berbasis Web," *J. Tek. ITS*, vol. 6, no. 2, 2017, doi: 10.12962/j23373539.v6i2.23978.
- [10] Y. N. Sari, "Jaringan Syaraf Tiruan *Backpropagation* Untuk Memprediksi Luas Area Serangan Hama Pada Tanaman Bawang," pp. 1–66, 2016.
- [11] A. Fitriadini, T. Pramiyati, and A. B. Pangaribuan, "Penerapan *Backpropagation Neural Network* Dalam Prediksi Harga Saham," *Semin. Nas. Mhs. Ilmu Komput. dan Apl.*, pp. 1–4, 2020.
- [12] J. Mirapeix, P. B. García-Allende, A. Cobo, O. M. Conde, and J. M. López-Higuera, "Real-time arc-welding defect detection and classification with principal component analysis and artificial neural networks," *NDT E Int.*, vol. 40, no. 4, pp. 315–323, 2007, doi: 10.1016/j.ndteint.2006.12.001.
- [13] A. Khumaidi, "Image Sequence Metode Convolution Neural Network (Cnn) Untuk Non Distructive Test . Image Sequence Metode Convolution Neural Network (Cnn) Untuk Non Distructive Test .," 2017.
- [14] N. Rinanto, M. T. Wahyudi, and A. Khumaidi, "Radial Basis Function Neural Network sebagai Pengklasifikasi Citra Cacat Pengelasan," *Rekayasa*, vol. 11, no. 2, p. 118, 2018, doi: 10.21107/rekayasa.v11i2.4418.
- [15] F. Duan, S. Yin, P. Song, W. Zhang, C. Zhu, and H. Yokoi, "Automatic Welding Defect Detection of X-Ray Images by Using Cascade AdaBoost with Penalty Term," *IEEE Access*, vol. 7, pp. 125929–125938, 2019, doi: 10.1109/ACCESS.2019.2927258.