

Implementasi Sistem Deteksi Visual Cacat Pengelasan Menggunakan Metode Image Processing Berbasis Raspberry Pi

Taufik Fathoni, Devan Junesco Vresdian, Arief Jaenul

Fakultas Teknik, Program Studi Elektro, Universitas Global Jakarta, Jakarta, Indonesia

Email: ¹092022030020@student.jgu.ac.id, ²devan@jgu.ac.id, ³ariep@jgu.ac.id

Email Penulis Korespondensi: 092022030020@student.jgu.ac.id

Submitted 20-02-2026; Accepted 09-04-2026; Published 28-04-2026

Abstrak

Penelitian ini mengembangkan sistem deteksi visual cacat pengelasan berbasis Raspberry Pi dengan memanfaatkan metode Gray Level Co-occurrence Matrix (GLCM), Histogram of Oriented Gradients (HOG), Principal Component Analysis (PCA), dan Support Vector Machine (SVM) untuk mengidentifikasi berbagai jenis cacat pengelasan, yaitu porositas, undercut, burn through, overlap, dan spatter. Sistem dirancang untuk bekerja secara otomatis dan real-time dengan tahapan proses yang meliputi akuisisi citra, pra-pemrosesan untuk meningkatkan kualitas gambar, segmentasi Region of Interest (ROI), ekstraksi fitur tekstur dan bentuk, reduksi dimensi menggunakan PCA, serta klasifikasi multikelas menggunakan SVM. Selain itu, penelitian ini bertujuan untuk mengevaluasi pengaruh kondisi akuisisi citra terhadap performa sistem, khususnya pada variasi pencahayaan, jarak, dan sudut kamera, yang merupakan faktor penting dalam implementasi di lingkungan industri. Pengujian dilakukan dengan beberapa skenario kondisi untuk memperoleh parameter optimal yang menghasilkan akurasi terbaik. Hasil pengujian menunjukkan bahwa kondisi optimal diperoleh pada pencahayaan sebesar 50 lux, jarak kamera 10 cm, dan sudut pengambilan gambar sebesar 20°. Pada kondisi tersebut, sistem mampu mencapai tingkat akurasi sebesar 100% untuk klasifikasi part normal, serta akurasi sebesar 94,4% pada klasifikasi multikelas. Nilai precision dan recall masing-masing mencapai 94%, dengan F1-score sebesar 93%, yang menunjukkan keseimbangan performa model dalam mendeteksi berbagai jenis cacat. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa sistem yang dikembangkan memiliki potensi tinggi sebagai solusi inspeksi kualitas pengelasan secara otomatis, efisien, dan real-time di lingkungan industri manufaktur.

Kata Kunci: Deteksi cacat pengelasan; GLCM; HOG; *Principal Component Analysis* (PCA); *Support Vector Machine* (SVM)

Abstract

This study develops a visual welding defect detection system based on Raspberry Pi by utilizing Gray Level Co-occurrence Matrix (GLCM), Histogram of Oriented Gradients (HOG), Principal Component Analysis (PCA), and Support Vector Machine (SVM) methods to identify various types of welding defects, including porosity, undercut, burn-through, overlap, and spatter. The system is designed to operate automatically and in real-time through several processing stages, including image acquisition, preprocessing to enhance image quality, Region of Interest (ROI) segmentation, feature extraction of texture and shape, dimensionality reduction using PCA, and multiclass classification using SVM. In addition, this study aims to evaluate the effect of image acquisition conditions on system performance, particularly variations in lighting, distance, and camera angle, which are critical factors in industrial implementation. Experiments were conducted under several scenarios to determine the optimal parameters that yield the best performance. The results show that the optimal condition is achieved at a lighting level of 50 lux, a camera distance of 10 cm, and a viewing angle of 20°. Under these conditions, the system achieves an accuracy of 100% for normal part classification and 94.4% for multiclass classification. The precision and recall values both reach 94%, with an F1-score of 93%, indicating a balanced performance in detecting different types of welding defects. Overall, the results demonstrate that the proposed system has strong potential as an effective, efficient, and real-time automated inspection solution for welding quality in industrial manufacturing environments.

Keywords: Welding defect detection; GLCM; HOG; *Principal Component Analysis* (PCA); *Support Vector Machine* (SVM)

1. PENDAHULUAN

Inspeksi kualitas hasil pengelasan di industri manufaktur masih banyak dilakukan secara visual manual oleh operator, sehingga rentan terhadap kesalahan akibat subjektivitas, keterbatasan penglihatan, dan kelelahan kerja. Kondisi ini menyebabkan cacat pengelasan berukuran kecil seperti *porosity*, *spatter*, atau *overlap* sering tidak terdeteksi atau justru salah diklasifikasikan, yang berdampak pada meningkatnya produk *reject*, *rework*, biaya produksi, serta potensi risiko keselamatan [1][2]. Oleh karena itu, diperlukan sistem inspeksi otomatis yang mampu bekerja secara konsisten, objektif, dan *real-time* untuk meningkatkan kualitas dan keandalan proses pengelasan. Selain kerugian ekonomi, cacat las yang lolos ke tahap perakitan juga berpotensi menimbulkan masalah keselamatan (*safety*) dan klaim kualitas dari pelanggan, yang pada akhirnya berdampak pada reputasi dan tingkat kepercayaan terhadap perusahaan [3]

Perkembangan teknologi *image processing* dan *machine learning* telah banyak dimanfaatkan dalam sistem inspeksi visual otomatis di bidang manufaktur [4][5][6]. Sebagian besar penelitian terdahulu menggunakan pendekatan *deep learning* seperti *Convolutional Neural Network* (CNN), *You Only Look Once* (YOLO), dan *U-Net* yang mampu menghasilkan akurasi tinggi, bahkan di atas 90%. Namun demikian, metode tersebut memiliki keterbatasan dalam implementasi pada perangkat *embedded* karena membutuhkan sumber daya komputasi tinggi, penggunaan GPU, serta dataset dalam jumlah besar untuk memperoleh performa optimal [7][8].

Di sisi lain, beberapa penelitian menggunakan pendekatan *image processing* dan *machine learning* ringan seperti *Gray Level Co-occurrence Matrix* (GLCM), *Histogram of Oriented Gradients* (HOG), *Principal Component Analysis* (PCA), dan *Support Vector Machine* (SVM) menunjukkan keunggulan dalam efisiensi komputasi. Meskipun demikian, penelitian-penelitian tersebut umumnya masih terbatas pada pengujian menggunakan dataset statis, aplikasi berbasis

desktop, atau belum mengintegrasikan sistem secara *real-time* serta belum mempertimbangkan variasi kondisi akuisisi citra di lingkungan industri maupun operasional nyata[9][10][11][12].

Berdasarkan tinjauan tersebut, *gap analysis* penelitian ini terletak pada minimnya sistem deteksi cacat pengelasan yang mengintegrasikan metode ekstraksi fitur dan klasifikasi ringan dalam satu sistem berbasis *embedded*, yang mampu bekerja secara *real-time* serta dianalisis terhadap variasi kondisi akuisisi citra di lingkungan industri. Sebagian besar penelitian sebelumnya masih berfokus pada peningkatan akurasi menggunakan metode *deep learning* dengan kebutuhan komputasi tinggi, atau menggunakan metode ringan yang belum diuji terhadap kondisi nyata seperti variasi pencahayaan, jarak, dan sudut pengambilan gambar, sehingga aspek implementasi di lingkungan industri masih belum dikaji secara komprehensif. Oleh karena itu, diperlukan suatu pendekatan yang tidak hanya efisien secara komputasi, tetapi juga mampu diimplementasikan secara langsung pada sistem *embedded* dan diuji dalam kondisi operasional yang mendekati lingkungan industri sebenarnya.

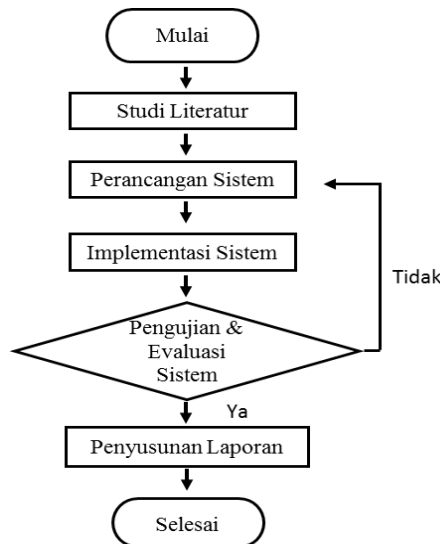
Tujuan penelitian ini adalah untuk merancang dan mengimplementasikan sistem deteksi visual cacat pengelasan berbasis Raspberry Pi yang mampu bekerja secara otomatis dan *real-time*. Selain itu, penelitian ini juga bertujuan untuk menganalisis pengaruh variasi kondisi akuisisi citra, meliputi pencahayaan, jarak, dan sudut kamera, terhadap performa sistem, serta mengevaluasi tingkat akurasi dalam mengklasifikasikan berbagai jenis cacat pengelasan seperti *porosity*, *undercut*, *burn-through*, *overlap*, dan *spatter*.

Kontribusi utama penelitian ini adalah pengembangan sistem deteksi cacat pengelasan berbasis Raspberry Pi yang mengintegrasikan metode ekstraksi fitur GLCM dan HOG dengan reduksi dimensi PCA serta klasifikasi SVM dalam satu sistem berbasis perangkat *embedded* yang mampu bekerja secara *real-time*. Selain itu, penelitian ini juga memberikan kontribusi dalam bentuk analisis pengaruh kondisi akuisisi citra terhadap performa sistem, yang masih jarang dibahas pada penelitian sebelumnya, khususnya pada implementasi di lingkungan industri nyata. Penelitian ini diharapkan dapat menghasilkan solusi inspeksi otomatis yang aplikatif, efisien, dan relevan bagi industri kecil dan menengah.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang disusun secara sistematis untuk memastikan sistem deteksi visual cacat pengelasan dapat bekerja sesuai dengan tujuan penelitian. Proses metodologi penelitian yang diterapkan dalam pengembangan sistem ini ditunjukkan secara skematis pada Gambar 1.



Gambar 1. Tahapan Penelitian

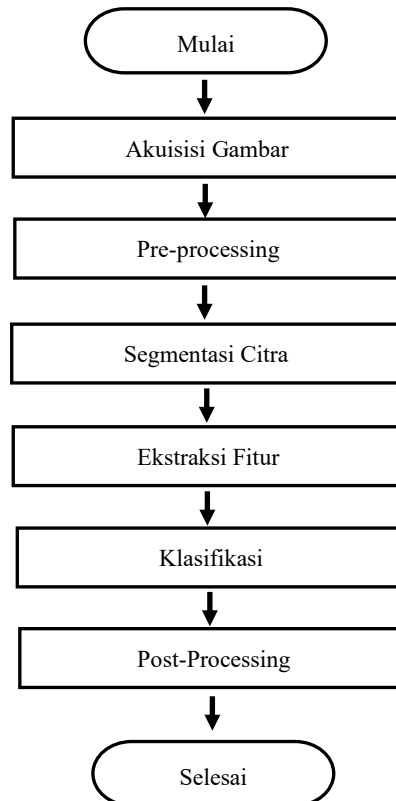
Berdasarkan Gambar 1, penelitian diawali dengan tahap studi literatur yang bertujuan untuk memahami konsep pengelasan, jenis cacat pengelasan, serta metode pengolahan citra dan machine learning yang digunakan, yaitu *Gray Level Co-occurrence Matrix* (GLCM), *Histogram of Oriented Gradients* (HOG), *Principal Component Analysis* (PCA), dan *Support Vector Machine* (SVM). Tahap selanjutnya adalah perancangan sistem yang meliputi perancangan perangkat keras dan perangkat lunak. Perangkat keras menggunakan Raspberry Pi sebagai unit pemrosesan utama yang terintegrasi dengan kamera untuk akuisisi citra. Pada sisi perangkat lunak, dirancang alur pengolahan citra yang mencakup proses pre-processing, segmentasi Region of Interest (ROI), ekstraksi fitur, reduksi dimensi, dan klasifikasi. Tahap implementasi sistem dilakukan dengan mengintegrasikan metode-metode yang digunakan ke dalam program berbasis Python pada Raspberry Pi[13]. Pada tahap ini, metode GLCM digunakan untuk mengekstraksi fitur tekstur citra hasil pengelasan [14], sedangkan HOG digunakan untuk menangkap karakteristik bentuk dan tepi objek [12]. Fitur yang dihasilkan kemudian direduksi dimensinya menggunakan PCA untuk meningkatkan efisiensi komputasi [15][16][17]. Selanjutnya, proses klasifikasi dilakukan menggunakan metode SVM untuk menentukan jenis-jenis cacat secara multikelas [18]. Tahap

berikutnya adalah pengujian dan evaluasi sistem untuk mengetahui kinerja metode yang digunakan. Pengujian dilakukan dengan variasi kondisi akuisisi citra seperti pencahayaan, jarak kamera, dan sudut kamera guna menganalisis pengaruhnya terhadap performa sistem. Tahap terakhir adalah penyusunan laporan yang berisi seluruh hasil penelitian, analisis, serta kesimpulan yang diperoleh

2.2 Penerapan Metode Image Processing

Pada penelitian ini, metode image processing diterapkan untuk mengolah citra hasil pengelasan guna memperoleh informasi yang relevan dalam proses deteksi cacat. Tahapan pengolahan citra dilakukan secara sistematis mulai dari pre-processing hingga klasifikasi.

Untuk menjelaskan alur kerja sistem deteksi cacat pengelasan yang dikembangkan, proses pengolahan citra secara keseluruhan ditunjukkan pada Gambar 2.



Gambar 2. Flowchart Alur Pengolahan Citra

Berdasarkan Gambar 2, alur kerja sistem deteksi cacat pengelasan dimulai dari tahap Mulai, yang merupakan proses inialisasi sistem, termasuk persiapan perangkat keras berupa Raspberry Pi dan kamera, serta pemuatan program pengolahan citra. Tahap berikutnya adalah Akuisisi Gambar, yaitu proses pengambilan citra hasil pengelasan menggunakan kamera sebagai input utama sistem. Citra yang diperoleh kemudian diproses pada tahap *Pre-processing*, yang bertujuan untuk meningkatkan kualitas citra, seperti pengurangan noise, konversi ke grayscale, dan normalisasi pencahayaan. Selanjutnya, citra masuk ke tahap Segmentasi Citra untuk memisahkan area penting atau *Region of Interest* (ROI) dari latar belakang sehingga fokus analisis hanya pada bagian pengelasan. Pada tahap Ekstraksi Fitur, dilakukan pengambilan karakteristik penting dari citra menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM) untuk fitur tekstur dan *Histogram of Oriented Gradients* (HOG) untuk fitur bentuk dan tepi objek. Fitur yang dihasilkan kemudian digunakan sebagai representasi data untuk proses selanjutnya. Tahap berikutnya adalah Klasifikasi, di mana fitur yang telah diperoleh sebelumnya diproses menggunakan metode *Support Vector Machine* (SVM) untuk menentukan kategori cacat pengelasan. Sebelum klasifikasi, dapat dilakukan reduksi dimensi menggunakan *Principal Component Analysis* (PCA) untuk meningkatkan efisiensi dan performa sistem. Setelah proses klasifikasi, dilakukan tahap *Post-Processing* yang bertujuan untuk menyempurnakan hasil deteksi, seperti penampilan hasil klasifikasi, pemberian label, atau penyaringan hasil agar lebih akurat dan mudah dipahami. Tahap terakhir adalah Selesai, yang menandakan bahwa seluruh proses deteksi telah dilakukan dan sistem menghasilkan output berupa informasi jenis cacat pengelasan.

2.3 Pengujian dan Evaluasi Sistem

Pengujian sistem dilakukan untuk mengevaluasi performa metode yang diusulkan dalam mendeteksi dan mengklasifikasikan cacat pengelasan. Pengujian meliputi pengujian statis untuk menentukan kondisi akuisisi citra optimal serta pengujian dinamis untuk menguji kemampuan sistem pada kondisi operasional nyata.

Sebagai acuan dalam proses pengolahan dan evaluasi sistem, spesifikasi dan distribusi data yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Hasil Prediksi

Prediksi Sistem	Kelas Positif	Kelas Negatif
Kelas Positif	TP	FN
Kelas Negatif	FP	TN

Tabel 1 menyajikan perbandingan antara hasil prediksi yang dihasilkan oleh sistem dengan data aktual sebagai acuan. Hasil pengujian tersebut kemudian dianalisis menggunakan confusion matrix dan tingkat akurasi untuk mengevaluasi keandalan sistem dalam mendeteksi cacat pengelasan sesuai dengan tujuan penelitian. Selanjutnya, hasil klasifikasi dikelompokkan ke dalam empat kategori evaluasi, yaitu True Positive (TP), False Positive (FP), True Negative (TN), dan False Negative (FN)[19].

Untuk menilai kinerja sistem secara lebih komprehensif, digunakan beberapa metrik evaluasi yang umum dalam permasalahan klasifikasi, yaitu *akurasi*, *presisi*, *recall*, dan *F1-score*. Metrik-metrik ini berfungsi untuk mengukur tingkat keberhasilan sistem dalam mengklasifikasikan citra, baik untuk kondisi normal maupun cacat (NG).[20]

a. Akurasi

Mengukur seberapa sering sistem melakukan prediksi yang benar.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (1)$$

atau

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Total seluruh data}} \times 100\% \quad (2)$$

b. Presisi

Mengukur ketepatan sistem dalam memprediksi kelas positif (NG).

$$\text{Presisi} = \frac{TP}{TP + FP} \times 100\% \quad (3)$$

c. Recall (sensitivitas)

Mengukur kemampuan sistem dalam menangkap seluruh data positif (cacat yang ada).

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (4)$$

d. F1-Score

Merupakan rata-rata dari presisi dan recall (gambaran kinerja secara keseluruhan).

$$\text{F1-Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \times 100\% \quad (5)$$

3. HASIL DAN PEMBAHASAN

3.1 Implementasi Sistem

Sistem deteksi visual cacat pengelasan diimplementasikan menggunakan Raspberry Pi yang terintegrasi dengan kamera, LCD, dan buzzer. Sistem bekerja secara otomatis dan *real-time* melalui tahapan pengolahan citra, mulai dari akuisisi hingga klasifikasi menggunakan Python. Hasil deteksi ditampilkan pada layar dan dapat disertai indikator buzzer, sehingga proses inspeksi menjadi lebih efisien. Untuk menggambarkan implementasi sistem, ditampilkan realisasi alat deteksi yang terdiri dari komponen utama yang terintegrasi.

Gambar 3 menunjukkan bentuk fisik alat yang digunakan dalam penelitian ini.



Gambar 3. Alat Deteksi Visual Cacat Pengelasan

Gambar 3 menunjukkan alat deteksi cacat pengelasan yang terdiri dari Raspberry Pi, kamera, LCD, dan buzzer yang terintegrasi dalam satu sistem. Seluruh komponen bekerja secara sinkron untuk mendukung proses deteksi secara otomatis dan *real-time*.

3.2 Implementasi Metode Pengolahan Citra

Pada tahap implementasi, metode pengolahan citra diterapkan secara bertahap untuk mengolah citra hasil pengelasan hingga menghasilkan informasi klasifikasi cacat. Setiap tahapan menghasilkan output yang digunakan sebagai input pada proses berikutnya.

3.2.1. Akuisisi Citra

Akuisisi citra dilakukan menggunakan kamera yang terhubung dengan Raspberry Pi untuk menangkap citra hasil pengelasan secara langsung. Proses pengambilan citra dilakukan dengan mempertimbangkan kondisi pencahayaan, jarak, dan sudut kamera agar diperoleh kualitas gambar yang optimal.

Output: citra hasil pengelasan dalam format RGB sebagai input awal sistem.

3.2.2 Pra-pemrosesan

Citra hasil akuisisi kemudian diproses pada tahap pra-pemrosesan untuk meningkatkan kualitas citra. Proses ini meliputi konversi citra ke grayscale, reduksi noise, serta normalisasi pencahayaan.

Output: citra yang lebih jelas dan siap digunakan pada tahap segmentasi.

3.2.3 Segmentasi ROI

Segmentasi dilakukan dengan menerapkan metode ROI untuk memisahkan area jalur pengelasan dari latar belakang. Hal ini bertujuan agar analisis hanya difokuskan pada bagian yang relevan.

Output: citra yang hanya berisi area jalur las.

3.2.4 Ekstraksi Fitur (GLCM dan HOG)

Pada tahap ini dilakukan ekstraksi fitur menggunakan metode GLCM dan HOG. GLCM digunakan untuk memperoleh karakteristik tekstur seperti *contrast*, *correlation*, *energy*, dan *homogeneity*, sedangkan HOG digunakan untuk menangkap informasi bentuk dan tepi objek.

Output: vektor fitur numerik yang merepresentasikan karakteristik citra yang berupa nilai-nilai fitur GLCM serta nilai histogram gradien hasil ekstraksi HOG. Vektor fitur ini kemudian digunakan sebagai input pada tahap reduksi dimensi dan proses klasifikasi.

3.2.5 Reduksi Dimensi (PCA)

Fitur hasil ekstraksi kemudian direduksi menggunakan PCA untuk mengurangi dimensi data dan meningkatkan efisiensi komputasi tanpa menghilangkan informasi penting.

Output: fitur dengan dimensi lebih ringkas yang tetap merepresentasikan informasi utama. Hasil reduksi ditunjukkan berupa grafik PCA

3.2.6 Klasifikasi (SVM)

Fitur hasil reduksi PCA digunakan sebagai input pada metode SVM untuk melakukan klasifikasi jenis cacat pengelasan secara multikelas.

Output: label klasifikasi berupa kondisi normal atau jenis cacat pengelasan.

3.3 Hasil Metode Pengolahan Citra

Pada tahap ini ditampilkan hasil pengolahan citra yang meliputi proses pra-pemrosesan dan segmentasi. Hasil ini bertujuan untuk menunjukkan perubahan kualitas citra sebelum dan sesudah dilakukan pengolahan, serta memastikan bahwa citra yang digunakan telah sesuai untuk tahap ekstraksi fitur.

3.3.1 Hasil Akuisisi Citra

Proses dimulai dengan pengambilan citra menggunakan kamera yang terhubung dengan Raspberry Pi. Citra yang ada tahap akuisisi citra, kamera yang terhubung dengan Raspberry Pi digunakan untuk menangkap citra hasil pengelasan secara langsung. Proses pengambilan citra dilakukan pada kondisi tertentu dengan mempertimbangkan pencahayaan, jarak, dan sudut kamera agar diperoleh kualitas gambar yang optimal sebagai input sistem.

Gambar 4 menunjukkan contoh citra hasil akuisisi yang digunakan dalam penelitian ini.




Gambar 4. Hasil Akuisisi citra

Berdasarkan Gambar 4, citra yang diperoleh masih dalam format RGB dan selanjutnya diproses pada tahap pra-pemrosesan.

3.3.2 Hasil Pra-pemrosesan

Pada tahap pra-pemrosesan, citra hasil akuisisi diolah untuk meningkatkan kualitas gambar melalui konversi *grayscale* dan reduksi noise.

Gambar 5 menunjukkan hasil pra-pemrosesan citra.



Gambar 5. Hasil Pra-Pemrosesan

Gambar 5 menampilkan hasil pra-pemrosesan menunjukkan peningkatan kejelasan pola tekstur pada permukaan pengelasan, sehingga perbedaan antara area las dan latar belakang menjadi lebih terlihat dan siap untuk diproses pada tahap segmentasi.

3.3.3 Hasil Segmentasi ROI

Segmentasi citra dilakukan dengan menerapkan metode *Region of Interest* (ROI) untuk memfokuskan area analisis pada bagian jalur pengelasan.

Gamabr 6 menunjukkan hasil segmentasi menggunakan ROI.



Gambar 6. Hasil Segmentasi ROI

Gambar 6 menunjukkan hasil segmentasi ROI bahwa area latar belakang di luar jalur las berhasil dihilangkan, sehingga citra yang dihasilkan hanya berisi bagian relevan dari permukaan pengelasan. Dengan penerapan ROI, gangguan dari objek di sekitar jalur las dapat diminimalkan, yang berdampak positif terhadap kestabilan proses ekstraksi fitur.

3.3.4 Ekstraksi Fitur (GLCM dan HOG)

Secara umum GLCM dapat memetakan hubungan antar piksel sehingga mampu membedakan antara tekstur yang halus, kasar, acak dan teratur sedangkan HOG menghasilkan fitur bentuk. Beberapa fitur statistik yang dihasilkan dari GLCM antara lain :

- a. *Contrast* (Mengukur perbedaan intensitas antar piksel).

$$Contrast = \sum_{i,j} (i - j)^2 \cdot P(i, j) \quad (6)$$

- b. *Correlation* (Mengukur keterkaitan hubungan antar piksel).

$$Correlation = \sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)P(i,j)}{\sigma_i \sigma_j} \quad (7)$$

- c. *Energy* (Mengukur keseragaman tekstur, nilai tinggi pada pola berarti tekstur halus).

$$Energy = \sum_{i,j} P(i, j)^2 \quad (8)$$

- d. *Homogeneity* (Mengukur kemiripan antar piksel).

$$Homogeneity = \sum_{i,j} \frac{P(i,j)}{1 + |i-j|} \quad (9)$$

- e. *Entropy* (Mengukur kompleksitas informasi gambar, jika nilai tinggi maka tekstur kompleks).

$$Entropy = \sum_{i,j} P(i, j) \log_2 (P(i, j)) \quad (5)$$

Keterangan :

$P(i, j)$ adalah nilai probabilitas pasangan piksel pada posisi (i, j) dalam GLCM

μ adalah rata-rata nilai intensitas

σ adalah standar deviasi

Tabel 2 menunjukkan nilai parameter GLCM yang diperoleh dari masing-masing kelas citra.

Tabel 2. Nilai Parameter GLCM dari Citra

Label data	<i>Contrast</i>	<i>Correlation</i>	<i>Energy</i>	<i>Dissimilarity</i>	<i>Homogeneity</i>
Normal	105-112	0.93 - 0.95	0.03 - 0.04	5.8 - 6.0	0.25 - 0.28
Burn through	87 -95	0.93 - 0.95	0.03 - 0.04	5.2 - 5.4	0.27 - 0.29
Undercut	84-87	0.94 - 0.95	0.4 - 0.6	5.5 - 5.6	0.25 - 0.26
Overlap	132 - 135	0.92 - 0.95	0.02 - 0.04	0.68 - 0.69	0.22 - 0.23
Porosity	141 - 145	0.89 - 0.90	0.03 - 0.04	0.66 - 0.67	0.25 - 0.26
Spatter	116 - 118	0.93- 0.94	0.02 - 0.03	0.65- 0.70	0.22- 0.23

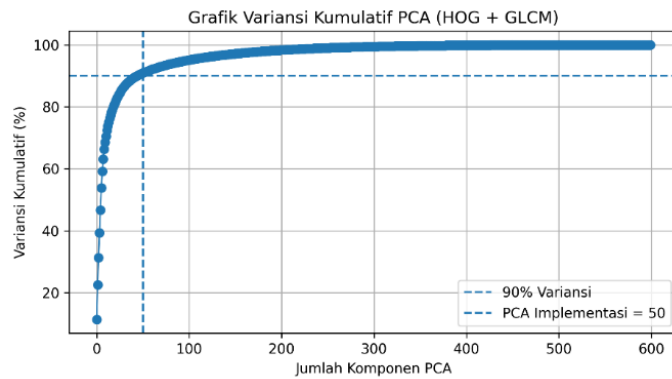
Berdasarkan Tabel 2, setiap jenis kondisi pengelasan memiliki karakteristik nilai fitur yang berbeda.

1. Citra las normal memiliki nilai *contrast* yang lebih rendah dan *homogeneity* yang lebih tinggi, menandakan permukaan las yang relatif rata dan seragam.
2. Citra dengan cacat pengelasan menunjukkan peningkatan *contrast* serta penurunan *homogeneity* dan *energy*, yang mengindikasikan tekstur permukaan yang lebih kasar dan tidak beraturan.
3. Cacat *porosity* dan *spatter* memperlihatkan perbedaan intensitas piksel yang paling signifikan akibat pola acak lubang dan percikan las.
4. *Undercut* dan *overlap* menampilkan perubahan tekstur yang lebih terarah di area tepi las. Nilai *correlation* yang menurun pada citra cacat menunjukkan berkurangnya keseragaman hubungan antar piksel dibandingkan kondisi normal.

3.2.5 Reduksi Dimensi (PCA)

Sebelum proses klasifikasi menggunakan Support Vector Machine (SVM), fitur hasil ekstraksi GLCM dan HOG direduksi dimensinya menggunakan metode Principal Component Analysis (PCA). Proses PCA dilakukan melalui beberapa tahapan, yaitu penyusunan data fitur, normalisasi data (mean centering), perhitungan matriks kovarians, penentuan eigenvalue dan eigenvector, pemilihan komponen utama berdasarkan kontribusi variansi, serta transformasi data ke ruang dimensi baru. Hasil reduksi dimensi ini mampu mengurangi redundansi fitur, meningkatkan efisiensi komputasi, serta mempertahankan informasi penting yang berpengaruh terhadap proses klasifikasi.

Gambar 7 menunjukkan grafik variansi kumulatif hasil PCA terhadap jumlah komponen yang digunakan.



Gambar 7. Grafik Variansi PCA

Berdasarkan Gambar 7, menunjukkan grafik variansi kumulatif hasil *Principal Component Analysis* (PCA) pada fitur gabungan HOG dan GLCM. Grafik memperlihatkan bahwa variansi kumulatif meningkat tajam pada jumlah komponen awal dan telah melampaui batas 90%. Hal ini menunjukkan bahwa sebagian besar informasi fitur dapat direpresentasikan secara efektif dengan jumlah komponen PCA yang relatif kecil. Dengan demikian, PCA mampu mengurangi dimensi data tanpa menghilangkan informasi penting sebelum proses klasifikasi menggunakan SVM.

3.2.6 Klasifikasi (SVM)

Pada tahap klasifikasi, fitur hasil reduksi dimensi menggunakan PCA digunakan sebagai input pada metode *Support Vector Machine* (SVM). Proses ini bertujuan untuk mengelompokkan citra hasil pengelasan ke dalam kelas normal maupun berbagai jenis cacat berdasarkan karakteristik fitur yang dimiliki.

Gambar 8 menunjukkan hasil klasifikasi menggunakan metode SVM.



Gambar 8. Hasil Klasifikasi (SVM)

Berdasarkan Gambar 8, sistem mampu mengklasifikasikan citra ke dalam kelas yang sesuai dengan karakteristiknya. Hasil ini menunjukkan bahwa metode SVM dapat digunakan secara efektif untuk membedakan kondisi normal dan berbagai jenis cacat pengelasan.

3.4 Pengujian dan Evaluasi Sistem

Pengujian sistem dilakukan untuk mengetahui pengaruh variasi kondisi akuisisi citra terhadap kinerja sistem. Variasi yang diuji meliputi pencahayaan, jarak kamera, dan sudut kamera.

3.4.1 Pengujian Statis Sistem

Pengujian statis sistem dilakukan untuk mengetahui kinerja awal sistem deteksi cacat pengelasan pada kondisi pengujian yang terkontrol. Pada pengujian ini, objek uji berada dalam keadaan diam dan parameter kamera diatur secara tetap, sehingga pengaruh faktor lingkungan dapat diminimalkan. Tujuan utama pengujian statis adalah untuk menentukan kondisi optimal kamera yang menghasilkan performa terbaik sistem. Kondisi optimal yang diperoleh dari pengujian statis ini selanjutnya digunakan sebagai standart parameter (baseline) pada pengujian dinamis.

Pengujian uji statis dilakukan dengan memvariasikan parameter pencahayaan 0–300 lux, jarak 10–40 cm, dan sudut 0–80 derajat. Hasil pengujian tersebut dirangkum untuk menentukan kondisi pengambilan citra yang optimal, sebagaimana disajikan pada Tabel 3.

Tabel 3. Ringkasan Hasil Pengujian Statis

No	Parameter Uji	Kondisi Pengujian	Hasil Deteksi	Keterangan
1	Intensitas Cahaya	0 lux	Tidak Terdeteksi	Citra terlalu gelap
2	Intensitas Cahaya	50 – 100 lux	Terdeteksi Optimal	Kualitas citra stabil
3	Intensitas Cahaya	150 – 200 lux	Terdeteksi	Noise mulai muncul
4	Intensitas Cahaya	250 – 300 lux	Kurang Optimal	Over exposure

5	Jarak Kamera	10 cm	Terdeteksi Optimal	Detail & area seimbang
6	Jarak Kamera	15 – 20 cm	Terdeteksi	Detail tinggi & area sempit
7	Jarak Kamera	25 – 30 cm	Kurang Optimal	Mulai blur
8	Jarak Kamera	35 – 40 cm	Kurang Optimal	Detail objek berkurang
9	Sudut Kamera	0°	Terdeteksi	Objek terlihat
10	Sudut Kamera	10° – 20°	Terdeteksi Optimal	Objek terlihat jelas
11	Sudut Kamera	30° – 50°	Kurang Optimal	Distorsi perspektif
12	Sudut Kamera	60° – 80°	Tidak Terdeteksi	Objek tidak terlihat

Berdasarkan Tabel 3, hasil uji statis menunjukkan bahwa parameter pengambilan citra memiliki pengaruh terhadap kinerja sistem deteksi visual cacat pengelasan. Kondisi optimal diperoleh pada intensitas cahaya 50–100 lux, jarak kamera 10 cm, dan sudut pengambilan gambar 10°–20°. Pada kondisi di luar rentang tersebut, kualitas citra menurun sehingga mempengaruhi hasil deteksi.

Gambar uji statis variasi pencahayaan.

3.4.2 Pengujian Dinamis Sistem

Pengujian dinamis sistem dilakukan untuk mengevaluasi kinerja sistem deteksi cacat pengelasan dalam kondisi operasional nyata. Pengujian ini dilakukan dengan menggunakan parameter optimal, yaitu intensitas pencahayaan sebesar 50–100 lux, jarak kamera 10 cm, dan sudut pengambilan gambar 10°–20°. Pada kondisi tersebut, sistem diuji untuk mendeteksi dan mengklasifikasikan cacat secara *real-time* guna mengetahui tingkat keandalan, kestabilan, serta akurasi sistem dalam kondisi dinamis.

a. Pengujian Variasi Pencahayaan

Pengujian dilakukan dengan variasi intensitas pencahayaan LED pada area pengelasan. Intensitas yang diuji adalah 50 lux dan 100 lux. Setiap pengujian dilakukan pada kondisi yang sama, termasuk jarak kamera, sudut pandang, dan posisi objek las. Tujuan pengujian ini adalah untuk menganalisis pengaruh perubahan intensitas pencahayaan terhadap kualitas citra yang diperoleh serta kinerja sistem dalam mendeteksi dan mengklasifikasikan cacat pengelasan secara akurat. Gambar 9 menunjukkan hasil pengambilan citra pada kondisi pencahayaan 50 lux.



Gambar 9. Intensitas Cahaya 50 lux

Berdasarkan Gambar 9 Intensitas cahaya 50 lux menghasilkan kontras citra yang baik dengan tingkat noise yang minimal, sehingga objek las dapat terdeteksi secara jelas.

Pengujian juga dilakukan pada kondisi pencahayaan sebesar 100 lux untuk mengetahui pengaruh intensitas cahaya yang lebih tinggi terhadap kualitas citra dan kinerja sistem.

Gambar 10 menunjukkan hasil pengambilan citra pada kondisi pencahayaan 100 lux



Gambar 10. Intensitas Cahaya 100 lux

Berdasarkan Gambar 10, intensitas cahaya 100 lux menghasilkan citra yang lebih terang, namun beberapa detail permukaan las mulai kurang jelas akibat pencahayaan yang berlebihan. Kondisi ini dapat mempengaruhi proses ekstraksi fitur dan menurunkan akurasi klasifikasi. Pengujian Variasi Jarak Kamera

b. Pengujian Variasi Jarak Kamera

Pengujian dilakukan dengan kamera ditempatkan pada jarak 10 cm dan 20 cm dari permukaan las. Pengujian ini bertujuan untuk menemukan jarak kamera yang optimal dalam memperoleh citra dengan kualitas terbaik, sehingga

proses ekstraksi fitur GLCM dan klasifikasi SVM dapat menghasilkan performa yang maksimal. Gambar 11 menunjukkan hasil pengambilan citra pada jarak kamera 10 cm.



Gambar 11. Jarak Kamera 10 cm

Berdasarkan Gambar 11. Pengambilan citra pada jarak 10 cm menghasilkan detail cacat yang terlihat jelas sehingga fitur dapat diekstraksi secara optimal.

Pengujian juga dilakukan pada kondisi jarak 20 cm untuk mengetahui pengaruh variasi jarak terhadap kualitas citra dan kinerja sistem. Gambar 12 menunjukkan hasil pengambilan citra pada jarak kamera 20 cm.



Gambar 12. Jarak Kamera 20 cm

Berdasarkan Gambar 12. Pengambilan citra pada jarak 20 cm menghasilkan detail cacat yang kurang jelas karena ukuran objek terlihat lebih kecil. Kondisi ini menyebabkan proses ekstraksi fitur menjadi kurang optimal

c. Pengujian Variasi Sudut Kamera

Pengujian dilakukan dengan kamera ditempatkan pada dua variasi sudut terhadap permukaan las, yaitu 0° dan 20° . Pengujian variasi sudut kamera bertujuan untuk mengetahui perbedaan posisi kamera terhadap performa sistem dalam mendeteksi cacat las. Sudut pengambilan citra berpengaruh pada tampilan tekstur, distribusi cahaya, serta kejelasan detail cacat. Gambar 13 menunjukkan hasil pengambilan citra pada sudut kamera 0°



Gambar 13. Sudut Kamera 0°

Berdasarkan Gambar 13, pengambilan citra pada sudut kamera 0° menunjukkan bahwa objek las dapat terdeteksi dengan cukup jelas, meskipun beberapa detail masih belum terlihat secara optimal.

Pengujian juga dilakukan pada kondisi sudut kamera 20° untuk mengetahui pengaruh variasi jarak terhadap kualitas citra dan kinerja sistem Gambar 14 menunjukkan hasil pengambilan citra pada sudut kamera 20°



Gambar 14. Sudut Kamera 20°

Gambar 14 Pengambilan citra pada sudut kamera 20° menunjukkan objek las terdeteksi optimal dengan sangat jelas.

d. Pengujian Kondisi Optimal

Pengujian pada kondisi optimal kamera pada pencahayaan 50 lux, jarak kamera 10 cm, dan sudut 20 derajat dilakukan untuk mengevaluasi kinerja sistem deteksi visual cacat pengelasan dalam kondisi operasional yang stabil dan mendekati penerapan nyata di lapangan.

1. Pengujian Part Normal

Pengujian dinamis dilakukan pada part normal untuk mengevaluasi performa sistem secara objektif, dan hasilnya digunakan sebagai dasar perhitungan akurasi.

Tabel 4 menunjukkan hasil pengujian sistem pada part normal.

Tabel 4. Pengujian Part Normal

No.	Jenis Data Uji	Hasil Prediksi	Keterangan
1	Normal	Normal	Benar
2	Normal	Normal	Benar
3	Normal	Normal	Benar
4	Normal	Normal	Benar
5	Normal	Normal	Benar
6	Normal	Normal	Benar
7	Normal	Normal	Benar
8	Normal	Normal	Benar
9	Normal	Normal	Benar
10	Normal	Normal	Benar
11	Normal	Normal	Benar
12	Normal	Normal	Benar
13	Normal	Normal	Benar
14	Normal	Normal	Benar
15	Normal	Normal	Benar
16	Normal	Normal	Benar
17	Normal	Normal	Benar
18	Normal	Normal	Benar
19	Normal	Normal	Benar
20	Normal	Normal	Benar
21	Normal	Normal	Benar
22	Normal	Normal	Benar
23	Normal	Normal	Benar
24	Normal	Normal	Benar
25	Normal	Normal	Benar

Berdasarkan Tabel 4, hasil pengujian part normal, sistem mampu mengklasifikasikan 25 dari 25 data uji secara benar sebagai kelas normal. Akurasi part normal dihitung menggunakan persamaan berikut:

Akurasi Part Normal

$$\begin{aligned}
 &= \frac{\text{Jumlah prediksi benar}}{\text{Total seluruh data}} \times 100 \% \\
 &= \frac{25}{25} \times 100 \% \\
 &= 100\%
 \end{aligned}$$

Sehingga diperoleh nilai akurasi sebesar 100%. Hasil ini menunjukkan bahwa sistem memiliki tingkat kestabilan yang baik dalam mendeteksi part normal pada kondisi objek bergerak dengan konfigurasi kamera optimal

2. Pengujian Part Multikelas

Pengujian seluruh kelas dilakukan untuk mengetahui kemampuan sistem dalam membedakan berbagai jenis cacat pengelasan serta kelas normal pada kondisi kamera optimal.

Tabel 5 menunjukkan hasil pengujian sistem pada part multikelas

Tabel 5. Pengujian Part Multikelas

No.	Kondisi / Jenis Cacat	No. Sampel	Kebenaran Deteksi
1	Normal	1	Benar
2		2	Benar

3		3	Benar
4	<i>Burn through</i>	1	Benar
5		2	Benar
6		3	Benar
7	<i>Porosity</i>	1	Benar
8		2	Benar
9		3	Salah
10	<i>Undercut</i>	1	Benar
11		2	Benar
12		3	Benar
13	<i>Overlap</i>	1	Benar
14		2	Benar
15		3	Benar
16	<i>Spatter</i>	1	Benar
17		2	Benar
18		3	Benar

Berdasarkan Tabel 5 Pengujian Part Multikelas dari 18 sample sistem memprediksi 17 benar dan 1 salah prediksi aktual *porosity* terdeteksi *undercut*.

3.4.2 Evaluasi Sistem

Untuk menganalisis kinerja sistem secara lebih rinci, dilakukan evaluasi menggunakan *confusion matrix*. Metode ini digunakan untuk mengetahui tingkat keberhasilan klasifikasi serta mengidentifikasi kesalahan prediksi pada setiap kelas. Tabel 6 menunjukkan hasil *confusion matrix* dari sistem deteksi cacat pengelasan.

Tabel 6. Tabel *Confusion Matrix*

Kelas	TP	FP	FN	TN
Normal	3	0	0	15
<i>Burn through</i>	3	0	0	15
<i>Porosity</i>	2	0	1	15
<i>Undercut</i>	3	1	0	15
<i>Overlap</i>	3	0	0	15
<i>Spatter</i>	2	0	1	15

Berdasarkan Tabel 6, sebagian besar kelas menunjukkan hasil klasifikasi yang baik dengan nilai *True Positive* yang tinggi dan kesalahan yang minimal. Namun, masih terdapat beberapa kesalahan klasifikasi, seperti pada kelas *porosity* dan *spatter* yang memiliki nilai *False Negative*, serta pada kelas *undercut* yang memiliki nilai *False Positive*. Hal ini menunjukkan bahwa meskipun sistem memiliki performa yang baik secara keseluruhan, masih terdapat beberapa kondisi yang berpotensi menyebabkan kesalahan dalam proses klasifikasi.

Menghitung precision, recall, dan F1-score perkelas

a. Kelas Normal

$$\text{Akurasi} = \frac{3 + 15}{3 + 15 + 0 + 0} = 100\%$$

$$\text{Precision} = \frac{3}{3 + 0} = 100\%$$

$$\text{Recall} = \frac{3}{3 + 0} = 100\%$$

$$\text{F1-score} = 2 \times \frac{1 \times 1}{1 + 1} = 100\%$$

b. Kelas *Burn through*

$$\text{Akurasi} = \frac{3 + 15}{3 + 15 + 0 + 0} = 100\%$$

$$\text{Precision} = \frac{3}{3 + 0} = 100\%$$

$$\text{Recall} = \frac{3}{3 + 0} = 100\%$$

$$\text{F1-score} = 2 \times \frac{1 \times 1}{1 + 1} = 100\%$$

c. Kelas *Porosity*

$$\text{Akurasi} = \frac{2 + 15}{3 + 15 + 0 + 0} = 94\%$$

$$\text{Precision} = \frac{2}{2 + 0} = 100\%$$

$$\text{Recall} = \frac{2}{2 + 1} = 67\%$$

$$\text{F1-score} = 2 \times \frac{0.67 \times 1}{0.67 + 1} = 80\%$$

d. Kelas *Undercut*

$$\begin{aligned} \text{Akurasi} &= \frac{2 + 15}{3 + 15 + 0 + 0} = 94\% \\ \text{Precision} &= \frac{2}{2 + 1} = 67\% \\ \text{Recall} &= \frac{3}{3 + 0} = 100\% \\ \text{F1-score} &= 2 \times \frac{1 \times 0.67}{1 + 0.67} = 80\% \end{aligned}$$

e. Kelas *Overlap*

$$\begin{aligned} \text{Akurasi} &= \frac{3 + 15}{3 + 15 + 0 + 0} = 100\% \\ \text{Precision} &= \frac{3}{3 + 0} = 100\% \\ \text{Recall} &= \frac{3}{3 + 0} = 100\% \\ \text{F1-score} &= 2 \times \frac{1 \times 1}{1 + 1} = 100\% \end{aligned}$$

f. Kelas *Spatte*

$$\begin{aligned} \text{Akurasi} &= \frac{3 + 15}{3 + 15 + 0 + 0} = 100\% \\ \text{Precision} &= \frac{3}{3 + 0} = 100\% \\ \text{Recall} &= \frac{3}{3 + 0} = 100\% \\ \text{F1-score} &= 2 \times \frac{1 \times 1}{1 + 1} = 100\% \end{aligned}$$

Karena sistem deteksi yang dikembangkan merupakan sistem klasifikasi *multi-class*, di mana citra hasil pengelasan diklasifikasikan ke dalam beberapa kelas, yaitu kondisi normal serta berbagai jenis cacat pengelasan, maka evaluasi kinerja sistem tidak cukup direpresentasikan hanya dengan satu kelas dominan. Sehingga nilai Precision, Recall, dan F1-Score dari nilai kinerja akhir sistem ditampilkan dalam bentuk *macro average*.

a. *Precision Average*

$$\begin{aligned} &= \frac{100+100+100+100+100+67}{6} \\ &= 94\% \end{aligned}$$

b. *Recall Average*

$$\begin{aligned} &= \frac{100+67+100+100+100+100}{6} \\ &= 94\% \end{aligned}$$

c. *F1-score Average*

$$\begin{aligned} &= \frac{100+80+100+100+100+80}{6} \\ &= 93\% \end{aligned}$$

Berdasarkan hasil *macro average*, diperoleh nilai *precision* 94%, *recall* 94%, dan *F1-score* 93%, yang menunjukkan bahwa sistem memiliki performa klasifikasi yang baik dan seimbang. Meskipun masih terdapat beberapa kesalahan pada kelas tertentu seperti *porosity*, *undercut*, dan *spatter*, secara keseluruhan sistem mampu mendeteksi dan mengklasifikasikan cacat pengelasan dengan akurasi yang tinggi.

4. KESIMPULAN

Sistem deteksi visual cacat pengelasan berbasis Raspberry Pi berhasil dikembangkan dengan mengombinasikan metode GLCM, HOG, PCA, dan SVM, serta mampu bekerja secara otomatis dan *real-time*. Performa sistem dipengaruhi oleh kondisi akuisisi citra, dengan hasil optimal pada pencahayaan 50–100 lux, jarak 10 cm, dan sudut 20°. Hasil pengujian menunjukkan akurasi 100% untuk part normal dan 94,4% untuk multikelas, dengan *precision* 94%, *recall* 94%, dan *F1-score* 93%, sehingga metode yang digunakan terbukti efektif untuk deteksi cacat pengelasan. Untuk pengembangan selanjutnya, disarankan peningkatan sistem pencahayaan dan mekanik agar kualitas citra lebih konsisten, serta penambahan analisis waktu pemrosesan untuk evaluasi performa dalam implementasi *real-time* di industri.

REFERENCES

- [1] A. Maulana, D. E. Yuliana, and D. A. W. Kusumastutie, "Weld Defect Classifier Using GLCM Extraction and ANN," *JTECS J. Sist. Telekomun. Elektron. Sist. Kontrol Power Sist. dan Komput.*, vol. 2, no. 2, p. 133, 2022, doi: 10.32503/jtecs.v2i2.2701.
- [2] Asni, M. W. B, and M. J. Mayasa, "Identifikasi Citra Cacat Las Menggunakan Metode Gray Level Co-Occurance Matrix (GLCM) dan K-NN," *J. Tek. Elektro Uniba (JTE UNIBA)*, vol. 7, no. 1, pp. 261–268, 2022, doi: 10.36277/jteuniba.v7i1.176.
- [3] A. Khumaidi and R. L. Pradana, "Identifikasi Penyebab Cacat Pada Hasil Pengelasan Dengan Image Processing Menggunakan Metode Yolo," *J. Tek. Elektro dan Komput. TRIAC*, vol. 9, no. 3, pp. 107–112, 2022, doi: 10.21107/triac.v9i3.15997.
- [4] I. A. P. et al. Ikhsanudin Ramadhan, Rilo Chandra Muhamadin, "Analisis kegagalan pada hasil pengelasan di pt. autokorindo

- pratama,” vol. 1, no. 1, pp. 36–42, 2024.
- [5] M. A. Amat and M. Luthfi, “Teknik Pemrosesan Gambar Digital pada Hasil Pengelasan TIG Aluminium Paduan untuk Aplikasi Pengukuran Lebar Manik Las,” vol. 2, no. 1, pp. 10–18, 2023.
- [6] N. Sujana, M. M. Mutoffar, and A. A. Haryanto, “UNTUK DETEKSI EKSPRESI WAJAH EMOSIONAL,” vol. 06, no. 02, pp. 115–124, 2024.
- [7] N. Saefulloh, J. Indra, and A. Ratna Juwita, “Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Kecacatan Pada Proses Welding di Perusahaan Manufacturing,” *Technol. Sci.*, vol. 6, no. 1, pp. 387–394, 2024, doi: 10.47065/bits.v6i1.5321.
- [8] H. Pan, “Pengenalan dan Klasifikasi Gambar Baru Metode Menggabungkan Pembelajaran Transfer Algoritma dan Model MobileNet untuk Cacat Pengelasan,” pp. 119951–119960, 2020.
- [9] A. Wira Bramantya and F. Utaminigrum, “Rancang Bangun Sistem Klasifikasi Tipe Permukaan Jalan menggunakan Gray Level Co-Occurrence Matrix (GLCM) dan Support Vector Machine (SVM) berbasis Raspberry Pi,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 2, pp. 552–558, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>
- [10] M. T. S. Azwar and Gusti, “Identifikasi Cacat Pada Kayu Menggunakan Fitur GLCM Dengan Metode SVM,” *J. Algoritm.*, vol. 3, no. 1, pp. 22–32, 2022.
- [11] M. V. Overbeek, “Histogram of Oriented Gradient (HOG) Untuk Deteksi Ekspresi Wajah Manusia,” *High Educ. Organ. Arch. Qual. J. Teknol. Inf.*, vol. 10, no. 2, pp. 81–86, 2018, doi: 10.52972/hoaq.vol10no2.p81-86.
- [12] O. Veza, “Development of the Histogram of Oriented Gradients (HOG) Method for Feature Extraction in Welding Defect Detection,” vol. 30, no. 10, pp. 2625–2633, 2025.
- [13] A. Ghimire, S. Alam, S. Giri, and M. P. Ghimire, “Cost-effective Deep Learning Infrastructure with NVIDIA GPU,” pp. 1–10, 2025, doi: 10.70530/kuset.v19i1.587.
- [14] C. Vasant Chaudhari, R. Kumar Gupta, and S. A. Feagade, “Steel Surface Defect Detection Using GLCM, HOG, Gabor Wavelet, And Random Forest Classifier,” *Turkish J. Comput. Math. Educ.*, vol. 12, no. 12, pp. 263–273, 2021.
- [15] M. Principal, C. Analysis, P. C. A. Sebagai, and P. A. Multikolinearitas, “METODE PRINCIPAL COMPONENT ANALYSIS (PCA) SEBAGAI PENANGANAN ASUMSI MULTIKOLINEARITAS,” *J. Mat. Stat. Dan Ter.*, vol. 02, no. 02, pp. 115–124, 2023.
- [16] O. Rute *et al.*, “METODE PRINCIPAL COMPONENT ANALYSIS (PCA) SEBAGAI PENANGANAN ASUMSI MULTIKOLINEARITAS,” vol. 13, no. 1, pp. 67–80, 2025.
- [17] I. A. Rosyada and D. T. Utari, “Penerapan Principal Component Analysis untuk Reduksi Variabel pada Algoritma K-Means Clustering,” *Jambura J. Probab. Stat.*, vol. 5, no. 1, pp. 6–13, 2024, doi: 10.37905/jjps.v5i1.18733.
- [18] S. Sriani and Y. Rizky, “Klasifikasi Kualitas Daun Tembakau Menggunakan Glcm (Gray Level Co-Occurrence Matrix) Dan Svm (Support Vector Machine),” *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 3342–3349, 2024, doi: 10.23960/jitet.v12i3.4599.
- [19] R. Alamsyah, I. J. Tarigan, and R. Yap, “Klasifikasi Jenis Sampah dengan Metode Gray Level Co-Occurrence Matrix (GLCM) dan Support Vector Machine (SVM),” *J. Armada Inform.*, vol. 7, no. 2, pp. 342–352, 2023, [Online]. Available: <http://jurnal.stmikmethodistbinjai.ac.id/jai/article/view/85>
- [20] F. Septarian and A. Nugroho, “Implementasi Naïve Bayes Classifier Untuk Klasifikasi Sentimen Pengguna Twitter Terhadap Kinerja Dpr,” *Semin. Nas. Mhs. Fak. Teknol. Inf.*, vol. 2, no. 2, pp. 483–492, 2023.