

## Review Komprehensif: Ekstraksi Fitur GLCM, GLRLM, dan LBP untuk Pendeteksian Korosi

Mizanul Ridho Aohana<sup>1</sup>, Ratu Nisful Laily Hidhayah<sup>2</sup>, Melki Jonathan Andara<sup>3</sup>, Nadya Amara<sup>4</sup>, Fitri Bimantoro<sup>5</sup>

<sup>1,2,3,4,5</sup>Teknik Informatika, Fakultas Teknik, Universitas Mataram

E-mail: <sup>1</sup>[mizanul.aohana@gmail.com](mailto:mizanul.aohana@gmail.com), <sup>2</sup>[ratunisful16@gmail.com](mailto:ratunisful16@gmail.com), <sup>3</sup>[melkijonathan2@gmail.com](mailto:melkijonathan2@gmail.com),  
<sup>4</sup>[nadyamaraa15@gmail.com](mailto:nadyamaraa15@gmail.com), <sup>5</sup>[bimo@unram.ac.id](mailto:bimo@unram.ac.id)

**Abstrak** – Penelitian ini mengeksplorasi solusi untuk mengatasi masalah korosi yang dapat mengancam pertumbuhan industri di Indonesia. Dengan tingginya tingkat investasi dalam sektor-sektor kunci seperti Transportasi, Gudang, Telekomunikasi, dan Pertambangan, risiko korosi menjadi perhatian serius. Korosi dapat menyebabkan kerusakan signifikan pada infrastruktur dan peralatan, menciptakan beban finansial yang besar jika tidak ditangani dengan cepat. Dalam penelitian ini, diajukan metode deteksi dini korosi dengan memanfaatkan ekstraksi fitur GLRLM, GLCM, dan LBP. Melibatkan model pendeteksi berbasis MLP, penelitian ini menitikberatkan pada sektor-sektor investasi utama di Indonesia. Hasil eksperimen menunjukkan keberhasilan metode ini, dengan tingkat akurasi berturut-turut sebesar 74,02%, 79,61%, dan 84,36%. Metode deteksi dini ini memberikan kontribusi besar terhadap upaya pencegahan korosi sejak dini, memungkinkan industri untuk mengidentifikasi potensi kerusakan pada tahap awal. Hal ini dapat mengurangi biaya perbaikan dan penggantian aset yang terkena dampak, memberikan keuntungan finansial bagi perusahaan dan negara secara keseluruhan. Penelitian ini relevan dengan pertumbuhan industri di Indonesia dan dapat menjadi landasan bagi strategi pencegahan korosi yang lebih efektif, khususnya dalam sektor-sektor yang menjadi pilar investasi utama negara. Dengan adanya solusi ini, diharapkan dapat meningkatkan ketahanan dan keberlanjutan infrastruktur industri di Indonesia.

**Kata Kunci** — Corrosion Detection, GLRLM, GLCM, LBP, MLP

### 1. PENDAHULUAN

Industri adalah penolong pertumbuhan perekonomian yang signifikan bagi Indonesia, Badan Statistika Pusat mencatat Jumlah perusahaan industri manufaktur skala menengah dan besar pada tahun 2022 mencapai sekitar 29 ribu usaha atau perusahaan [1]. Menurut data yang dikeluarkan oleh Kementerian Investasi atau Badan Koordinasi Penanaman Modal (BKPM) mengungkapkan realisasi penyertaan modal dalam negeri (PMDN) mencapai Rp. 178,2. Kemudian, secara sektor, PMDN mendominasi di sektor Transportasi, Gudang dan Telekomunikasi Rp 24,8 triliun; Pertambangan Rp. 22,3 triliun, Perumahan, Kawasan Industri dan Perkantoran Rp. 16,6 triliun [2]. Dengan tingginya tingkat investasi dalam sektor-sektor kunci seperti transportasi, gudang, telekomunikasi, dan pertambangan, risiko korosi menjadi perhatian serius.

Korosi merupakan fenomena penurunan kondisi logam akibat reaksi elektrokimia dengan lingkungan pada udara terbuka, disebut juga dengan korosi atmosfer. Korosi atmosfer dipengaruhi akibat topografi dan iklim lingkungan seperti temperatur, kelembapan, dan kandungan bahan kimia dalam udara sehingga dapat mempengaruhi laju korosi [3]. Korosi merupakan ancaman serius bagi perindustrian yang berkaitan langsung dengan logam, struktur baja, dan perlengkapan lainnya. Kerusakan akibat korosi dapat mengakibatkan penurunan kinerja, biaya perawatan yang tinggi, serta risiko kecelakaan kerja yang berpotensi fatal.

Berdasarkan permasalahan tersebut diperlukan sebuah solusi untuk mendeteksi korosi, pemetaan area dan level karat sehingga penanganan dapat dilakukan lebih cepat dan efisien. Oleh karena itu, penelitian ini akan membahas solusi deteksi dini korosi secara komprehensif dengan menggunakan metode ekstraksi fitur GLCM, GLRLM, dan LBP. Pendekatan ini memungkinkan analisis gambar korosi secara mendalam, menghasilkan informasi yang beragam mengenai struktur dan pola korosi. Proses pendeteksian korosi melibatkan analisis gambar yang telah mengalami kerusakan akibat korosi, dengan setiap metode ekstraksi fitur memberikan kontribusi informasi unik. Metode GLCM membantu mengukur perubahan tekstur benda akibat karat dengan menganalisis tingkat keabuan yang *co-occur* pada jarak dan sudut tertentu. Peningkatan korelasi pada jarak tertentu bisa menandakan daerah yang terkena karat [4], [5] dan metode GLRLM membantu mendeteksi pola linear pada citra permukaan yang terkena karat. Karat cenderung terbentuk dalam garis atau pola yang mengikuti permukaan benda. Dengan mengukur panjang *run* tingkat keabuan dalam berbagai arah, GLRLM membantu mengidentifikasi daerah dengan karakteristik linear, yang bisa menunjukkan adanya karat [6], [7]. Alasan menggunakan GLCM dan GLRLM terkait dengan pendeteksian korosi pada pipa menggunakan teknik tersebut menghasilkan tingkat akurasi korosi rata-rata sebesar 92,81% [6]. Penelitian ini juga menggunakan MLP, berdasarkan salah satu penelitian membuktikan penggunaan MLP dengan GLCM menghasilkan akurasi sebesar 73,5% pada klasifikasi wayang [5]. Penggunaan LBP digunakan untuk mendeteksi perubahan pola biner piksel

yang diakibatkan oleh karat [8], memungkinkan identifikasi daerah dengan variasi tekstur kompleks, yang menandakan kemungkinan adanya karat.

Pada penelitian identifikasi citra bahan kulit hewan, *Local Binary Pattern* (LBP) dan *Grey Level Run Length Matrix* (GLRLM) digunakan sebagai metode ekstraksi fitur tekstur menggunakan klasifikasi *Artificial Neural Network* (ANN). Penelitian ini menggunakan gambar bahan kulit hewan yang diklasifikasi menjadi lima kategori yaitu kulit sapi, babi, domba, kambing, dan kanguru. Akurasi yang dicapai dengan penerapan metode LBP dan GLRLM untuk mengidentifikasi citra kulit hewan adalah 60% [9].

Penelitian lain mengaplikasikan GLRLM pada pendeteksian COVID dengan menggunakan GLRLM dan *Extreme Learning Machine* (ELM). Tahap ekstraksi fitur menggunakan metode GLRLM memvisualisasikan fitur SRE dan LRE. Terlihat bahwa nilai SRE pada citra normal lebih kecil dibandingkan pada citra COVID-19, sementara nilai LRE pada citra normal lebih tinggi dibandingkan pada citra COVID-19. Hal ini mengindikasikan bahwa citra COVID-19 memiliki tekstur yang lebih kasar dari pada citra normal dan hasil dari *Learning Machine* menghasilkan akurasi sebesar 92%, sensitivitas 89.62%, dan spesifisitas 94.68%. Ini menandakan bahwa model ini memiliki kinerja yang sangat baik dalam mendeteksi COVID-19 melalui citra *X-Ray* [10].

Pada penelitian deteksi kematangan buah melon dengan algoritma *Support Vector Machine* Berbasis Ekstraksi Fitur GLCM. Menggunakan teknik ekstraksi fitur GLCM untuk menganalisis tekstur buah melon dan menerapkan algoritma SVM untuk mengatasi klasifikasi citra digital. Hasil penelitian menunjukkan bahwa teknik ekstraksi fitur GLCM dapat membantu dalam deteksi kematangan buah melon dengan tingkat akurasi sebesar 78,67% [11].

Pada penelitian Implementasi *Gray Level Co-Occurrence Matrix* (GLCM) untuk Klasifikasi Penyakit Daun Padi GLCM digunakan untuk ekstraksi fitur pada citra keabu-abuan (*grayscale*) dari daun padi yang terinfeksi penyakit. akurasi klasifikasi menggunakan metode GLCM dan KNN diperoleh akurasi sebesar 93,3% [12].

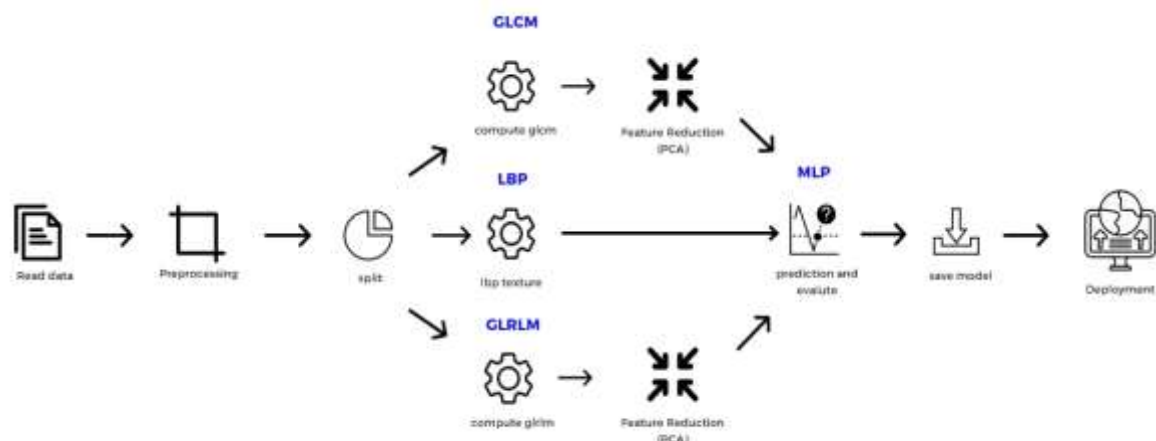
Penelitian lain yaitu Klasifikasi Batik dengan Ekstraksi Fitur Tekstur *Local Binary Pattern* dan Metode *K-Nearest Neighbor*. Metode *local binary pattern* dapat digunakan untuk mengenali pola tekstur pada batik sebagai fitur pada citra. Hasil yang didapat dari penggunaan metode LBP pada pengolahan citra digital batik adalah fitur tekstur yang dapat digunakan untuk membedakan kelas batik dengan akurasi sebesar 65% menggunakan metode *K-Nearest Neighbor* (KNN)[13].

Hasil dari analisis ini diharapkan dapat memberikan pemahaman yang lebih mendalam tentang kondisi korosi pada tingkat mikro, memungkinkan langkah-langkah penanganan yang lebih terarah dan efektif. Untuk mengatasi masalah di industri diperlukan sebuah sistem untuk mendeteksi korosi pada benda. Berdasarkan referensi yang sudah dipaparkan sebelumnya peneliti mencoba untuk melakukan komparatif analisis menggunakan metode GLCM, GLRLM dan LBP.

## 2. METODE PENELITIAN

### 2.1 Proposed Work

Dalam penelitian ini, peneliti mengusulkan tahap proses yang dimulai dengan membaca data, selanjutnya dilakukan *preprocessing*. Berdasarkan Gambar 1, *preprocessing* yang dilakukan yaitu *me-resize dataset* untuk mempercepat pemrosesan data. *Dataset* di *resize* dengan ukuran 256 x 256 yang kemudian datanya akan disimpan dalam folder yang berbeda. *Dataset* tersebut kemudian di-*split* menjadi beberapa folder untuk memproses *dataset* dengan berbagai metode. Model yang diperoleh dari pemrosesan tersebut kemudian disimpan dan dapat di *deploy* untuk kepentingan lainnya.



Gambar 1. Alur Penelitian

## 2.2 Pengumpulan *Dataset*

Pengumpulan data pada penelitian ini dilakukan dengan menerapkan metode *Image Retrieval*. *Image Retrieval* merupakan sistem penting untuk mengambil gambar serupa dengan melakukan pencarian dan penjelajahan di dalam basis data besar. *Image Retrieval* dapat menjadi alat yang dapat diandalkan untuk mengoptimalkan penggunaan akumulasi gambar, dan menemukan metode yang efisien untuk mengambil gambar [14].

## 2.3 *Dataset Preprocessing*

*Preprocessing* merupakan suatu teknik untuk meningkatkan kualitas gambar agar memperoleh hasil terbaik dari hasil yang diperoleh. Metode klasik yang umum digunakan meliputi deteksi tepi, peningkatan kontras, pengurangan *noise* gambar, dan normalisasi warna gambar. Sering digunakan untuk memfokuskan dan memperoleh gambar dari objek penelitian, dan metode deviasi standar sering digunakan untuk menampilkan warna gambar dengan lebih jelas [15].

Langkah pertama dalam mengelola *dataset* adalah melakukan pengecekan satu per satu terhadap entri data untuk mengidentifikasi duplikasi. Setelah itu, dilakukan pengecekan terhadap kevalidan label pada *dataset*. Data yang memiliki label yang salah akan segera dihapus atau dipindahkan. Terakhir, proses *resizing* gambar dilakukan untuk melakukan *preprocessing*, sehingga ukuran gambar disamakan untuk memudahkan proses pengolahan selanjutnya [16].

## 2.4 Metode Ekstraksi

Dalam penelitian ini, digunakan 3 metode ekstraksi antara lain adalah *Gray Level Run Length Matrix* (GLRLM), *Gray Level Co-Occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP).

### 2.2.1 GLRLM

GLRLM merupakan metode ekstraksi tekstur yang memiliki *output* berupa atribut statistik orde tinggi dengan mengestimasi piksel piksel dengan derajat keabuan yang sama pada arah tertentu. GLRLM mampu menggambarkan tekstur yang merupakan ciri penting untuk menunjukkan informasi struktur permukaan suatu citra [17]. Keunggulan metode GLRLM mampu membedakan citra halus dan citra kasar, dimana citra yang memiliki tekstur halus akan memiliki sedikit piksel tetangga yang intensitasnya sama sedangkan yang memiliki tekstur kasar akan memiliki banyak piksel tetangga yang intensitasnya sama [18], [19].

### 2.2.2 GLCM

*Gray Level Co-Occurrence Matrix* (GLCM) merupakan suatu metode yang terbentuk berdasarkan citra *Grayscale*. *Matrix* tersebut menghitung frekuensi kemunculan suatu nilai *pixel* horizontal terhadap *pixel* vertikal yang bersebelahan maupun diagonal [7] *Gray Level Co-Occurrence Matrix* (GLCM) merupakan metode yang menguntungkan untuk melakukan analisis tekstur citra, namun parameter dalam menghitung GLCM suatu citra dapat dipilih dari jarak yang luas, yang menghasilkan komputasi dalam jumlah besar [20].

### 2.2.3 LBP

Metode *Local Binary Pattern* pertama kali diperkenalkan oleh Ojala et al. Menurut Ojala et al. *Local Binary Pattern* merupakan metode yang digunakan sebagai ukuran tekstur *grayscale* yang terbukti efektif dan invarian terhadap pencahayaan yang berbeda. LBP dimanfaatkan untuk deskripsi tekstur dan didukung oleh komposisi pola mikro yang dapat dijelaskan oleh sebuah operator [21].

Semua LBP adalah deskriptor tekstur yang dapat juga digunakan untuk mewakili objek, karena gambar objek dapat dilihat sebagai sebuah komposisi *micro texture pattern* yaitu suatu operator non parametrik yang menggambarkan tata ruang lokal citra. Metode LBP mengubah tekstur dari suatu citra *input* menjadi nilai biner, dan nilai tersebut mewakili bagian dari piksel piksel suatu objek yang membentuk sebuah lingkaran dan memiliki pusat sebagai acuan terhadap nilai-nilai tersebut [17].

## 2.5 *Principal Component Analysis*

Metode *Principal Component Analysis* (PCA) merupakan sebuah metode yang digunakan untuk menyederhanakan suatu data. Metode ini ditemukan oleh Karl Pearson pada tahun 1901 dan digunakan dalam biologi. Sejak teori ini ditemukan kembali oleh Karhunen pada tahun 1947 dan dikembangkan lebih lanjut oleh Loewe pada tahun 1963, maka teori ini disebut juga transformasi Karhunen-Loewe dalam bidang ilmu telekomunikasi. Analisis komponen utama (PCA) adalah teknik statistik yang mengubah sebagian besar variabel yang awalnya berkorelasi menjadi sekumpulan variabel baru yang lebih kecil dan saling independen. Oleh karena itu, analisis komponen utama (PCA) membantu mereduksi data dan memfasilitasi interpretasi data [22]

PCA adalah kombinasi linier dari variabel pertama. Secara geometris, kombinasi linier ini merupakan sistem koordinat baru yang diperoleh dengan memutar sistem koordinat asli sebanyak kali. Metode PCA sangat berguna ketika data Anda yang ada memiliki jumlah variabel yang banyak dan korelasi antar variabel. Perhitungan analisis komponen utama didasarkan pada perhitungan nilai *eigen* dan vektor *eigen* yang mewakili

sebaran data dari *dataset*. PCA digunakan untuk menjelaskan struktur matriks varians-kovarians dari suatu set variabel melalui kombinasi linier dari variabel-variabel tersebut. Secara umum PCA dapat berguna untuk seleksi fitur dan interpretasi variabel-variabel [23].

## 2.6 Algoritma *Machine Learning*

MLP adalah salah satu arsitektur ANN paling populer. Hal ini diyakini sebagai yang pertama memperkenalkan MLP menggunakan algoritma pelatihan *backpropagation*. Jaringan *multilayer* biasanya menggunakan fungsi aktivasi *sigmoid* di lapisan tersembunyi. Fungsi-fungsi ini terkadang disebut fungsi "*squashing*" karena fungsi ini memampatkan rentang masukan tak terbatas menjadi rentang keluaran terbatas. Fungsi *sigmoid* dicirikan oleh kemiringan yang mendekati 0 seiring dengan meningkatnya masukan. Hal ini menyebabkan masalah saat menggunakan penurunan paling curam untuk melatih jaringan *multilayer* dengan fungsi *sigmoid*. Hal ini disebabkan karena ukuran gradien yang sangat kecil dapat mengakibatkan perubahan bobot yang kecil dan bias yang jauh dari optimal [24].

Arsitektur MLP-ANN terdiri dari sekumpulan *node* yang saling berhubungan yang terdiri dari tiga jenis lapisan: *input*, lapisan tersembunyi, dan *output*. Berikut penjelasan masing-masing *layer*:

### a. *Input Layer*

Lapisan masukan yang menerima nilai masukan dari setiap record dalam data Anda. Jumlah *node* masukan sesuai dengan jumlah variabel prediktor.


### b. *Hidden Layer*

Lapisan tersembunyi mengubah nilai masukan dalam jaringan. Setiap *node* pada lapisan tersembunyi terhubung ke *node* lapisan tersembunyi sebelumnya atau dari *node* lapisan masukan, dan terhubung ke *node* lapisan tersembunyi berikutnya atau *node* lapisan keluaran. Jumlah lapisan tersembunyi bisa mencapai.

### c. *Output Layer*

Garis yang terhubung ke lapisan keluaran berasal dari lapisan tersembunyi atau lapisan masukan dan mengembalikan nilai keluaran yang sesuai dengan variabel prediktor. *Output* dari lapisan *output* biasanya berupa nilai *floating point* antara 0 dan 1 [25].

Ilustrasi berbagai komponen MLP dengan lapisan tersembunyi. Lapisan masukan hanya mengirimkan nilai masukan  $x_i$  ke unit-unit yang ada pada lapisan tersembunyi dan tidak melakukan operasi apapun terhadap sinyal masukan. Lapisan tersembunyi menerima sinyal dari *node* lapisan masukan dan mengubahnya menjadi sinyal, yang dikirim ke semua *node* keluaran dan diubah menjadi keluaran. Bobot koneksi dari masukan ke *node* lapisan tersembunyi dan dari lapisan tersembunyi ke lapisan keluaran disesuaikan menggunakan algoritma penurunan paling curam. Algoritma ini digunakan untuk menyelesaikan permasalahan *nonlinier* [25].



Gambar 2. Arsitektur *Multi-Layer Perceptron*

Algoritma *machine learning* yang digunakan untuk melatih fitur korosi dalam penelitian ini adalah *Multi-Layer Perceptron*. *Multi-Layer Perceptron* atau MLP merupakan salah satu model *supervised learning* dalam *Artificial Neural Network* (ANN) yang memiliki jumlah neuron yang dapat disesuaikan dengan kebutuhan. Alasan dari pemilihan algoritma ini adalah kemampuan MLP dalam menangani tugas prediksi kompleks dan dapat belajar dari pola yang rumit dalam data. Dalam konteks ini, ekstraksi fitur menggunakan metode GLCM (*Gray Level Co-occurrence Matrix*), GLRLM (*Gray Level Run Length Matrix*), dan LBP (*Local Binary Pattern*) memberikan representasi yang kaya dan informatif tentang struktur tekstur gambar korosi.

MLP memiliki keunggulan dalam mengekstraksi dan memodelkan pola yang kompleks dari data bertipe gambar, sehingga dapat secara efektif memanfaatkan informasi yang dihasilkan oleh metode ekstraksi fitur seperti GLRLM, GLCM, dan LBP. Dengan kemampuan ini, MLP dapat memahami hubungan antara fitur-fitur

ekstraksi dan tingkat korosi yang terkait, sehingga memungkinkan untuk melakukan prediksi korosi dengan tingkat akurasi yang tinggi.

Dengan menggunakan MLP untuk melatih model prediksi korosi, penelitian ini dapat mengoptimalkan proses pembelajaran mesin untuk menemukan pola-pola yang kompleks dan tersembunyi dalam data ekstraksi fitur. Hasilnya diharapkan dapat memberikan prediksi yang akurat terkait tingkat korosi berdasarkan fitur-fitur yang diekstraksi menggunakan GLCM, GLRLM, dan LBP.

### 2.7 Metrik Evaluasi

Untuk mengukur keakuratan dari model yang diperoleh, digunakan *matrix* evaluasi yaitu *confusion matrix*, *Confusion Matrix* adalah sebuah tabel yang digunakan untuk mengevaluasi performa dari suatu model klasifikasi pada *machine learning*. *Confusion matrix* memuat empat nilai evaluasi utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN).

Tabel 1. *Confusion Matrix*

	Prediction	
	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	TP	TN
<i>Negative</i>	FP	FN

Dengan menggunakan nilai-nilai evaluasi dari Tabel 1, dapat dihitung matriks evaluasi berupa akurasi (*accuracy*), presisi (*precision*), dan *recall*. Berikut merupakan persamaan yang digunakan untuk menghitung nilai evaluasi.

*Accuracy* dihitung dengan membagi jumlah *True Positive* (TP) dan *True Negative* (TN) oleh total nilai keseluruhan. dinyatakan dalam persamaan 1.

$$Accuracy = \frac{TP+TN}{TP+FN+FP+TN} \dots\dots\dots(1)$$

*Recall* akan mengukur tingkat positif aktual dari hasil prediksi, untuk menghitung nilai tersebut, dinyatakan dalam persamaan 2.

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(2)$$

*Precision* memberikan nilai tingkat positif yang sebenarnya dari hasil prediksi, persamaannya dinyatakan dalam persamaan 3.

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(3)$$

ROC atau *Receiver Operating Characteristic* merupakan sebuah grafik yang mengilustrasikan kemampuan diagnostik dari sistem pengklasifikasi biner karena variasi ambang diskriminasi. dinyatakan dalam persamaan 4.

$$ROC = \frac{P(x|positive)}{P(x|negative)} \dots\dots\dots(4)$$

Dalam penelitian ini, penulis akan menggunakan akurasi, presisi, *recall* dan ROC sebagai metrik evaluasi untuk semua algoritma yang akan diuji [26]

### 2.8 Area Under Curve (AUC)

*Area Under Curve* (AUC) adalah ukuran dari luas area di bawah suatu kurva, dan nilainya selalu berada di antara 0 dan 1. AUC dihitung dengan menggabungkan luas trapesium yang terbentuk oleh titik-titik yang mewakili sensitivitas dan spesifisitas. Metrik ini mengevaluasi kinerja diskriminatif dengan memperkirakan probabilitas model dalam mengklasifikasikan sampel yang dipilih secara acak dari populasi positif atau negatif.

AUC berfungsi sebagai indikator akurasi model prediksi, dan perhitungannya melibatkan penilaian seberapa baik model dapat membedakan antara kelas. Nilai AUC berkisar antara 0 dan 1, di mana nilai yang lebih tinggi menunjukkan klasifikasi yang lebih kuat. AUC pada dasarnya merupakan ukuran kemampuan model untuk menyusun peringkat instansi positif lebih tinggi daripada instansi negatif [27].

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Hasil dan Diskusi

Berdasarkan metodologi yang telah dijelaskan sebelumnya, *dataset* yang digunakan dalam penelitian ini diperoleh melalui proses pengambilan data dari *Google Image* menggunakan kata kunci "karat". *Dataset* ini terbagi menjadi dua kelas, yakni kelas korosi dan kelas non-korosi, dengan jumlah gambar pada masing-masing label secara berturut-turut sebanyak 990 data untuk kelas korosi dan 829 data untuk kelas non-korosi. Proses pengumpulan *dataset* melalui metode *scraping* menghasilkan gambar-gambar karat yang berasal dari berbagai objek dengan bentuk yang beragam. Contoh *dataset* dapat dilihat pada Gambar 3 dan Gambar 4



Gambar 3 *Dataset* Non-Korosi



Gambar 4 *Dataset* Korosi

Gambar 3 dan 4 merupakan gambar *dataset* yang digunakan dalam mekanisme percobaan yang akan dilakukan. Tingginya variasi dalam *dataset* ini diharapkan memberikan keuntungan dalam proses pelatihan model, karena model akan terlatih dengan berbagai bentuk gambar atau objek. Keberagaman ini diharapkan dapat membantu model untuk memahami karakteristik karat dengan lebih baik, termasuk aspek-aspek seperti warna, tekstur, dan bentuk dari gambar-gambar tersebut.

#### 3.2 Analisis Komparatif

Dalam mekanisme *training* model pada penelitian ini, akan digunakan algoritma *Multi-Layer Perceptron*. Tabel 2. menunjukkan arsitektur yang digunakan pada masing-masing fitur. Standarisasi arsitektur ini dilakukan untuk mendapatkan hasil analisis yang lebih komprehensif.

Tabel 2. Arsitektur Model MLP

Fitur	<i>Learning Rate</i>	<i>Activation</i>	<i>Epoch</i>	<i>Hidden Layer</i>	<i>Solver</i>
GLRLM	<i>constant</i>	relu	200	200	adam
GLCM	<i>constant</i>	relu	200	300,	adam
LBP	<i>constant</i>	relu	200	100,50	adam

*Learning rate* constant pada Tabel 2 menunjukkan laju pembelajaran dari model akan tetap sama sepanjang pelatihan. Fungsi aktivasi pada lapisan *hidden layer* adalah relu atau *rectified linear*, fungsi ini yang akan mengkonversi setiap nilai *input* negatif menjadi nol dan membiarkan nilai positif tidak berubah. *Hidden layer* yang digunakan dalam setiap mekanisme *training* sudah disesuaikan dengan hasil performa yang paling optimal, sehingga digunakan jumlah *hidden layer* tersebut sebagai acuan.

Berdasarkan arsitektur yang sudah dibangun tersebut, maka dilakukan berbagai percobaan untuk mendapatkan hasil akurasi tertinggi dari ketiga metode GLRLM, GLCM, dan LBP. Proses ini melibatkan kombinasi berbagai fitur, pengulangan, evaluasi ulang, dan penyesuaian pada fitur-fitur yang digunakan, Metode GLCM menggunakan 24 fitur awal yang kemudian mengalami proses reduksi dengan PCA, menghasilkan 15 komponen. Sementara GLRLM menggunakan 44 fitur awal yang juga mengalami proses reduksi dengan PCA dan menghasilkan 15 komponen. Sedangkan untuk Metode LBP (*Local Binary Patterns*) tidak memiliki fitur terpisah seperti layaknya GLRLM dan GLCM. LBP sendiri sebenarnya adalah sebuah metode untuk mengekstraksi fitur dari citra kemudian merepresentasikannya ke dalam sebuah vektor. Teknik ini bekerja dengan cara membandingkan intensitas piksel dengan tetangganya secara lokal dan menghasilkan kode biner yang merepresentasikan pola tekstur di area tersebut. Dari percobaan yang sudah dilakukan, hasil percobaan dapat dilihat dalam Tabel 3.

Tabel 3. Fitur Hasil PCA

Percobaan	Daftar Fitur	Acc	P	R	AUC
GLRLM	SRE0,SRE45, SRE90,SRE135, LRE0, LRE45,LRE90, LRE135, GLN0,GLN45, GLN90, GLN135, RLN0,RLN45, RLN90, RLN135, RP0, RP45, RP90, RP135, LGLRE0, LGLRE45, LGLRE90, LGLRE135, HGL0, HGL45, HGL90, HGL135, SRLGLE0, SRLGLE45, SRLGLE90, SRLGLE135, SRHGLE0, SRHGLE45, SRHGLE90, SRHGLE135, LRLGLE0, LRLGLE45, LRLGLE90, LRLGLE135, LRGHLE0, LRGHLE45, LRGHLE90, LRGHLE135	74.02%	72.81%	82.29%	83.54%
GLCM	Contrast0, Contrast45 Contrast90, Contrast135, Dissimilarity0, Dissimilarity45, Dissimilarity90, Dissimilarity135, Homogeneity0, Homogeneity45, Homogeneity90, Homogeneity135, Energy0, Energy45 Energy90, Energy135, Correlation0, Correlation45, Correlation90, Correlation135, ASM0, ASM45, ASM90, ASM135	77.09%	78.35%	79.17%	85.76%
GLRLM with PCA	SRLGLE90, SRLGLE0, SRLGLE45, SRLGLE135, SRE45, SRE135, RLN45, LRE45, RLN135, LRE135, GLN45, RP45, HGL135, SRHGLE135, LRE0	74.02%	73.24%	81.25%	82.50%
GLCM with PCA	Correlation135, Contrast135, Homogeneity135, Dissimilarity135, Energy135, Correlation90, Contrast90, Contrast0, ASM135, Energy0, ASM0, Energy90, Homogeneity0, Dissimilarity90, Correlation0	79.61%	79.60%	83.33%	86.96%
LBP	-	84.36%	83.01%	89.06%	91.22%

Dari Tabel 3. hasil terbaik diperoleh menggunakan LBP dengan akurasi sebesar 84,36% dan AUC sebesar 91.22%. Disusul oleh GLCM with PCA dengan akurasi sebesar 79.61% dan GLCM dengan akurasi sebesar 77.09%. Hasil ini menunjukkan bahwa konsep LBP dalam mengenali pola hubungan biner lokal antara piksel dan tetangganya mampu menggambarkan perubahan piksel akibat korosi dengan lebih baik. Hal ini disebabkan karena LBP dirancang secara mikro untuk mengenali tekstur yang ada pada setiap piksel citra.


Sedangkan, jika melihat perbandingan antara algoritma GLCM dan GLRLM, performa terbaik diberikan oleh GLCM. Perbedaan ini kemungkinan besar disebabkan oleh kemampuan GLCM untuk menangkap hubungan spasial kompleks antara intensitas piksel yang mungkin lebih relevan dalam membedakan area korosi daripada informasi yang diukur oleh GLRLM tentang panjang dan jumlah *run* piksel yang mengalami korosi.

Selain itu, hal yang tidak kalah menarik ditunjukkan oleh penggunaan PCA dalam percobaan algoritma GLCM dan GLRLM. Dari analisis data yang terdapat dalam tabel 3, terlihat bahwa penerapan *Principal Component Analysis* (PCA) mampu meningkatkan tingkat akurasi GLCM dan GLRLM. Meskipun demikian, dapat dicatat bahwa metode *Local Binary Pattern* (LBP) tetap menjadi pilihan unggul dengan tingkat akurasi tertinggi untuk pendeteksian karat dibandingkan dengan penggunaan PCA pada metode *Gray Level Co-occurrence Matrix* (GLCM) atau *Gray Level Run Length Matrix* (GLRLM).

Berikut adalah grafik hasil *training* dengan menggunakan metode *Local Binary Pattern*, detail grafik dapat dilihat pada Gambar 5 dan Gambar 6.



Gambar 4. Grafik Loss



Gambar 5. *Confusion Matrix* dan *ROC Curve*

Gambar 4. menunjukkan bahwa loss yang didapatkan dalam pelatihan ini mengalami penurunan yang sangat halus dari 0.7 ke nilai loss 0.15, akurasi *training* yang diperoleh sebesar 94% dan 84% untuk test *accuracy* menggunakan LBP. Sedangkan Gambar 5. menunjukkan bahwa hasil *confusion matrix* dari validasi yang sudah dilakukan, kemudian terdapat kurva ROC yang menggambarkan hubungan antara *True Positive Rate* (*Sensitivity*) dan *False Positive Rate* ( $1 - \textit{Specificity}$ ). Tren yang ditunjukkan oleh kurva ROC ini sangat baik, hal ini direpresentasikan dari hasil AUC yang mendapatkan skor sebesar 91.22%.

#### 4. SIMPULAN

Berdasarkan hasil penelitian, dicapai tingkat akurasi tertinggi sebesar 94% untuk *training* dan 84% untuk test menggunakan metode *Local Binary Pattern* (LBP), diikuti oleh *Gray Level Co-occurrence Matrix* (GLCM) dengan akurasi *training* sebesar 83% dan test sebesar 79%. Sementara itu, metode *Gray Level Run Length Matrix* (GLRLM) menunjukkan akurasi terendah, dengan *training accuracy* 79% dan test *accuracy* 74%. Perbedaan hasil ini dapat diatribusikan pada karakteristik masing-masing metode ekstraksi fitur. Dalam konteks deteksi karat dengan variasi objek yang beragam dalam gambar, LBP terbukti menjadi metode ekstraksi fitur yang paling efektif untuk mengenali korosi. Kesimpulan ini memberikan wawasan penting dalam pemilihan metode ekstraksi fitur yang sesuai untuk aplikasi deteksi korosi, dengan implikasi pada peningkatan kinerja model dalam memahami pola tekstur dan ciri-ciri kritis dalam citra karat.

#### 5. SARAN

Untuk meningkatkan kualitas dan efektivitas sistem deteksi korosi, disarankan untuk melibatkan eksplorasi lebih lanjut dengan mengimplementasikan algoritma *training* alternatif seperti *Learning Vector Quantization* (LVQ), *Support Vector Machine* (SVM) ataupun dengan algoritma *deep learning*. Selain itu, dapat dilakukan proses *hypertuning* parameter pada model dan melakukan segmentasi dalam proses *preprocessing* agar dapat memberikan peningkatan signifikan dalam akurasi dan efisiensi. Dalam konteks *dataset*, dianjurkan untuk melakukan pembenahan pada kualitas data dengan melakukan standarisasi *dataset* dan menangani potensi anomali serta menambah jumlah data untuk mencakup lebih banyak variasi citra korosi. Penggabungan saran-saran ini diharapkan dapat memperkuat kinerja sistem deteksi korosi dan meningkatkan kemampuannya untuk mengenali dengan akurat pola-pola tekstur yang berkaitan dengan korosi.

#### DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, Direktori Industri Manufaktur Indonesia 2022. Jakarta: Badan Pusat Statistik, 2022. Accessed: Dec. 26, 2023. [Online]. Available: <https://www.bps.go.id/id/publication/2022/09/30/cbc730b4a2e4ebc36749998c/direktori-industri-manufaktur-indonesia-2022.html>
- [2] CNBC Indonesia, "BKPM: Investasi Dalam Negeri Capai Rp178 T di Kuartal III," 20 October 2023.
- [3] A. M. S. C. A. S. A. R. N. I. T. S. F. S. H. Affandi, "Analisa Korosi Atmosferik Baja Karbon Rendah di Kecamatan Medan Belawan," vol. 14, Nov. 2020.
- [4] "Wayang Image Classification Using MLP Method and GLCM Feature Extraction," *Journal of Computer Science, Information Technology and Telecommunication Engineering*, Sep. 2020, doi: 10.30596/jcositte.v1i2.5131.
- [5] N. D. Hoang, "Image Processing-Based Pitting Corrosion Detection Using Metaheuristic Optimized Multilevel Image Thresholding and Machine-Learning Approaches," *Math Probl Eng*, vol. 2020, 2020, doi: 10.1155/2020/6765274.
- [6] J. P. Sari, A. Erlansari, and E. P. Purwandari, "Identifikasi Citra Digital Kura-Kura Sumatera Dengan Perbandingan Ekstraksi Fitur Glcm dan Glrlm Berbasis Web," 2021. [Online]. Available: [www.ejournal.unib.ac.id/index.php/pseudocode](http://www.ejournal.unib.ac.id/index.php/pseudocode)



- 
- [7] Marwan Noor Fauzy, “Perbandingan Tekstur Citra Dalam Klasifikasi Motif Batik Menggunakan Metode Gray Level Co-Occurrence Matrix (GLCM) dan Gray Level Run Length Matrix (GLRLM),” Program PascaSarjana Universitas Amikom Yogyakarta, Yogyakarta, 2020.
- [8] S. H. Khaleefah, S. A. Mostafa, A. Mustapha, and M. F. Nasrudin, “Review of local binary pattern operators in image feature extraction,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 19, no. 1, pp. 23–31, 2020, doi: 10.11591/ijeecs.v19.i1.pp23-31.
- [9] M. Hafizd, M. M. Santoni, and A. Muliawati, *Level Run Length Matrix Untuk Identifikasi Citra Bahan Kulit Hewan*.
- [10] Y. S. HARIYANI, S. HADIYOSO, and T. S. SIADARI, “Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network,” *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 8, no. 2, p. 443, May 2020, doi: 10.26760/elkomika.v8i2.443.
- [11] R. A. Saputra, D. Puspitasari, and T. Baidawi, “Deteksi Kematangan Buah Melon dengan Algoritma Support Vector Machine Berbasis Ekstraksi Fitur GLCM.” [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/infortech200>
- [12] A. A. Huda, B. Setiaji, and F. R. Hidayat, “Implementasi Gray Level Co- Occurrence Matrix (GLCM) Untuk Klasifikasi Penyakit Daun,” 2022. [Online]. Available: [www.ejournal.unib.ac.id/index.php/pseudocode](http://www.ejournal.unib.ac.id/index.php/pseudocode)
- [13] M. T. Kanugroho, M. A. Rahman, and R. C. Wihandika, “Klasifikasi Batik dengan Ekstraksi Fitur Tekstur Local Binary Pattern dan Metode K-Nearest Neighbor,” 2022. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [14] B. I. Khaleel, “Color Image Retrieval Based On Fuzzy Neural Networks and Swarm Intelligence,” *IJUM Engineering Journal*, vol. 23, no. 1, pp. 116–128, 2022, doi: 10.31436/IJUM.EJ.V23I1.1802.
- [15] Z. A. A. R. Z. G. D. Ucta Pradema Sanjaya, “Optimasi Convolutional Neural Network dengan Standard Deviasi untuk Klasifikasi Pneumonia pada Citra X-rays Paru,” *Fakultas Sains dan Teknologi Universitas Nahdlatul Ulama Sunan Giri*, vol. 7, no. 3, Jul. 2023.
- [16] A. Brijith, “Data Preprocessing for Machine Learning.” [Online]. Available: <https://www.researchgate.net/publication/375003512>
- [16] O. Pribadi, “Bulletin Of Computer Science Research Aplikasi Pembeda Daging Sapi dan Babi dengan Metode Color Moment dan Local Binary Pattern Histogram,” *Media Online*, vol. 3, no. 5, pp. 336–342, 2023, doi: 10.47065/bulletincsr.v3i5.260.
- [17] Idamatul Bashiroh, “Deteksi Osteoporosis Melalui Analisis Tekstur Citra Tulang Manusia Pada Wanita Pasca Menopause dengan Menggunakan Metode Ekstraksi Fitur Gray Level Run Length Matrix (GLRLM) dan Klasifikasi Adaptive Neuro Fuzzy Inference System (Anfis),” *Universitas Islam Negeri Maulana Malik Ibrahim Malang, Malang*, 2023.
- [18] A. Puteri Bilqis Salsabila et al., “Identifikasi Citra Jenis Bunga menggunakan Algoritma KNN dengan Ekstraksi Warna HSV dan Tekstur GLCM,” *Technomedia Journal (TMJ)*, doi: 10.33050/tmj.v6i1.
- [19] L. B. Coelho, D. Zhang, Y. Van Ingelgem, D. Steckelmacher, A. Nowé, and H. Terry, “Reviewing machine learning of corrosion prediction in a data-oriented perspective,” *npj Materials Degradation*, vol. 6, no. 1. Nature Publishing Group, Dec. 01, 2022. doi: 10.1038/s41529-022-00218-4.
- [20] D. Retnoningrum, A. W. Widodo, and M. A. Rahman, “Ekstraksi Ciri Pada Telapak Tangan Dengan Metode Local Binary Pattern (LBP),” 2019. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [21] A. Z. W. S. D. S. M. S. Noya Van Delsen, “Penerapan Metode Analisis Komponen Utama untuk Mereduksi Faktor-faktor Inflasi di Kota Ambon,” vol. 11, no. 2, Dec. 2017.
- [22] M. Z. Nasution, “Penerapan Principal Component Analysis (PCA) dalam Penentuan Faktor Dominan yang Mempengaruhi Prestasi Belajar Siswa (Studi Kasus: SMK Raksana 2 Medan),” *Jurnal Teknologi Informasi*, vol. 3, no. 1, 2019.
- [23] P. Hosseinzadeh Talaee, “Multilayer perceptron with different training algorithms for streamflow forecasting,” *Neural Comput Appl*, vol. 24, no. 3–4, pp. 695–703, Mar. 2014, doi: 10.1007/s00521-012-1287-5.
- [24] A. Setiadi Jurusan Manajemen Informatika Akademi Manajemen Informatika dan Komputer Bina Sarana Informatika Karawang Jl Banten No, “PENERAPAN ALGORITMA MULTILAYER PERCEPTRON UNTUK DETEKSI DINI PENYAKIT DIABETES.” [Online]. Available: <http://archive.ics.uci.edu/ml/>.
- [25] M. Hasnain, M. F. Pasha, I. Ghani, M. Imran, M. Y. Alzahrani, and R. Budiarto, “Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking,” *IEEE Access*, vol. 8, pp. 90847–90861, 2020, doi: 10.1109/ACCESS.2020.2994222.
- [26] D. A. Setiawan, H. Fitriyah, and W. Kurniawan, “Sistem Klasifikasi Jenis Karat Menggunakan Metode Decision Tree Berbasis Raspberry Pi,” 2019. [Online]. Available: <http://j-ptiik.ub.ac.id>
-