

SKRIPSI

IMPLEMENTASI EKSTRAKSI FITUR *GRAY LEVEL CO-OCCURRENCE MATRIX*, *LOCAL BINARY PATTERN* DAN *HUE SATURATION VALUE* UNTUK KLASIFIKASI PENYAKIT DAUN TOMAT

IMPLEMENTATION OF GRAY LEVEL CO-OCCURRENCE MATRIX, LOCAL BINARY PATTERN AND HUE SATURATION VALUE FEATURE EXTRACTION FOR TOMATO LEAF DISEASE CLASSIFICATION

Diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana
Teknik



IQ ANDI IMAN

D0220358

**PROGRAM STUDI INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS SULAWESI BARAT
MAJENE**

2024

LEMBAR PENGESAHAN

SKRIPSI

IMPLEMENTASI EKSTRAKSI FITUR *GRAY LEVEL CO-OCCURRENCE MATRIX, LOCAL BINARY PATTERN* DAN *HUE SATURATION VALUE* UNTUK KLASIFIKASI PENYAKIT DAUN TOMAT

Disusun dan diajukan oleh:

IQ ANDI IMAN

NIM. D0220358

Telah dipertahankan di hadapan Panitia Ujian yang dibentuk dalam rangka Penyelesaian Studi Program Sarjana Teknik Informatika Fakultas Teknik

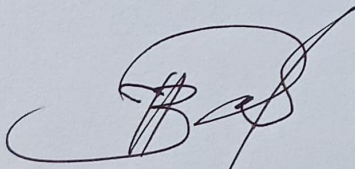
Universitas Sulawesi Barat

pada tanggal 21 November 2024

dan dinyatakan telah memenuhi syarat kelulusan.

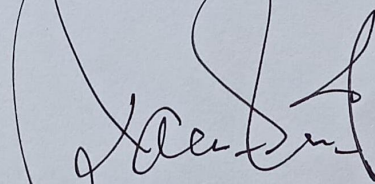
Menyetujui,

Pembimbing I



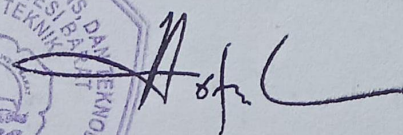
Nahya Nur, S.T., M.Kom
NIP. 199111052019032024

Pembimbing II



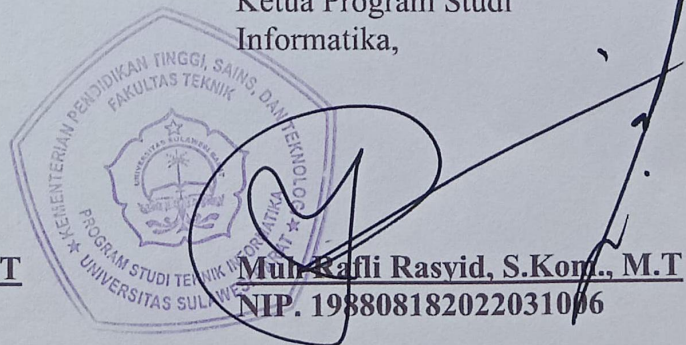
Farid Wajidi, S.Kom., M.T
NIP. 198904182019031018

Dekan Fakultas Teknik,
Universitas Sulawesi Barat



Dr. Ir. Hafsah Nirwana, M.T
NIP. 196404051990032002

Ketua Program Studi
Informatika,



Muh Rafli Rasyid, S.Kom., M.T
NIP. 198808182022031006

LEMBAR PERSETUJUAN

SKRIPSI

IMPLEMENTASI EKSTRAKSI FITUR *GRAY LEVEL CO-OCCURRENCE MATRIX, LOCAL BINARY PATTERN* DAN *HUE SATURATION VALUE* UNTUK KLASIFIKASI PENYAKIT DAUN TOMAT

Telah dipersiapkan dan disusun oleh:

IQ ANDI IMAN

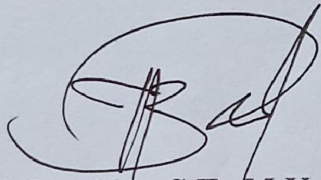
D0220358

Telah dipertahankan di depan Tim Penguji

Pada Tanggal 27 Juni 2024

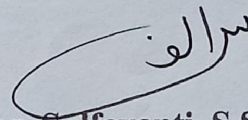
Susunan Tim Penguji:

Pembimbing I



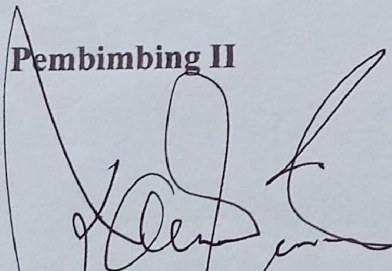
Nahya Nur, S.T., M.Kom
NIP. 199111052019032024

Penguji I



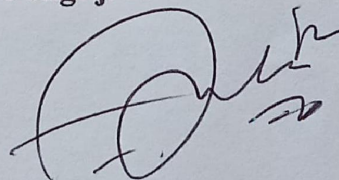
Dr. Eng. Sulfayanti, S.Si., M.T
NIP. 198903172020122011

Pembimbing II



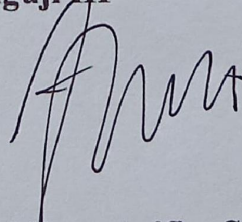
Farid Wajidi, S.Kom., MT
NIP. 198904182019031018

Penguji II



Siti Aulia Rachmini, S.T., M.T.
NIP. 198207062008042003

Penguji III



Nurhikma Arifin, S.Kom., MT
NIP. 199304252022032011

ABSTRAK

Iq Andi Iman Implementasi Ekstraksi Fitur *Gray Level Co-Occurrence Matrix*, *Local Binary Pattern* dan *Hue Saturation Value* Untuk Klasifikasi Penyakit Daun Tomat (dibimbing oleh **Nahya Nur** dan **Farid Wajidi**).

Tomat adalah tanaman bernilai ekonomi tinggi yang rentan terhadap penyakit daun yang disebabkan oleh jamur, bakteri, dan virus. Identifikasi penyakit secara visual oleh petani seringkali kurang efisien, sehingga diperlukan teknologi klasifikasi berbasis pengolahan citra. Penelitian ini bertujuan untuk mengevaluasi hasil klasifikasi penyakit daun tomat menggunakan ekstraksi fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP), serta ekstraksi warna *Hue Saturation Value* (HSV), baik secara terpisah maupun dalam kombinasi. Metode eksperimen digunakan dengan algoritma *Deep Neural Network* (DNN) pada rasio data 80:20, dilakukan analisis fitur *Gray Level Co-occurrence Matrix* (GLCM) pada empat sudut. Hasil penelitian menunjukkan bahwa kombinasi kedua fitur *Gray Level Co-occurrence Matrix* (GLCM), dan *Hue Saturation Value* (HSV) pada sudut 45° memberikan akurasi tertinggi sebesar 97,40%, sementara pada rasio data 70:30 kombinasi *Local Binary Pattern* (LBP) dan *Hue Saturation Value* (HSV) menghasilkan akurasi sebesar 97,32%. Kesimpulan ini menunjukkan bahwa kombinasi kedua ekstraksi fitur tersebut mampu meningkatkan akurasi model secara signifikan dibandingkan dengan penggunaan fitur tunggal, membantu petani dalam mengenali penyakit daun tomat dengan lebih cepat dan akurat.

Kata Kunci : *Deep Neural Network*, *Gray Level Co-occurrence Matrix*, *Hue Saturation Value*, *Local Binary Pattern*, Penyakit Daun, Tomat.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Tomat merupakan tanaman hortikultura yang memiliki nilai ekonomi tinggi dan banyak ditanam oleh masyarakat Indonesia (Sigitta et al., 2023). Di dalam buah tomat terdapat kandungan vitamin serta mineral yang dibutuhkan oleh tubuh manusia, diantaranya adalah vitamin A, vitamin C, kalsium, potasium, dan juga fosfat (Hadi, 2023). Tanaman tomat banyak dibudidayakan oleh petani, baik pada dataran rendah maupun dataran tinggi dan dapat tumbuh hampir di berbagai negara (Kultsum & Subekti, 2021).

Tanaman tomat rentan terhadap berbagai penyakit yang menyerang daun, disebabkan oleh jamur, bakteri, dan virus. Penyakit-penyakit ini dapat dikenal secara visual melalui ciri-ciri tekstur dan warna yang unik. Namun, pengenalan visual oleh petani seringkali memerlukan waktu yang lama dan tidak selalu akurat karena adanya kemiripan antara penyakit yang satu dengan yang lainnya (Salih et al., 2020). Oleh karena itu, diperlukan metode yang memudahkan petani dalam mengidentifikasi penyakit tanaman tomat, salah satunya melalui klasifikasi menggunakan pengolahan citra. Teknologi ini memungkinkan identifikasi penyakit secara efisien tanpa memerlukan keahlian khusus yang tinggi, sehingga petani dapat mengenali jenis-jenis penyakit dengan lebih mudah dan cepat mengambil tindakan pencegahan.

Selain itu, klasifikasi penyakit dengan pengolahan gambar juga membuka peluang untuk pengembangan sistem pendukung keputusan yang lebih canggih dan terintegrasi, memberikan rekomendasi solusi yang lebih tepat dalam menangani penyakit tanaman. Klasifikasi merupakan teknik pembelajaran data untuk menghasilkan prediksi nilai dari serangkaian atribut. Klasifikasi banyak digunakan untuk memprediksi kelas pada label tertentu, yaitu dengan mengklasifikasi data (membangun model) berdasarkan training set dan nilai-nilai (label kelas) dalam mengklasifikasikan atribut tertentu (Tangkelayuk, 2022). Sebelum dilakukan proses klasifikasi, diperlukan tahap ekstraksi fitur dalam analisis data atau pengolahan citra.

Ekstraksi fitur adalah langkah-langkah dalam analisis data atau pemrosesan gambar sebelum klasifikasi, yang bertujuan untuk mengidentifikasi karakteristik penting dari data mentah guna memudahkan interpretasi dan pengenalan pola (Torres-García et al. 2022). Dalam klasifikasi penyakit tanaman tomat, ekstraksi fitur sangat krusial karena informasi yang diperoleh dari citra digunakan untuk membedakan dan mengklasifikasikan kondisi tanaman. Penelitian ini menggunakan dua jenis ekstraksi fitur, yaitu *Gray Level Co-occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP). GLCM adalah metode yang efektif untuk merekam citra, dengan beberapa keunggulan seperti pengurangan beban komputasi dan kemampuan mempertahankan pengenalan tinggi karena proses kuantisasi yang membantu mengurangi kebisingan pada citra. Metode ekstraksi fitur GLCM memiliki fitur-fitur seperti kontras, korelasi, energi, dan homogenitas, yang dikenal efektif serta memiliki akurasi dan komputasi yang baik dibandingkan metode ekstraksi tekstur lainnya (Laksono et al., 2023). GLCM ini telah terbukti sangat kuat sebagai fitur deskriptor dalam menampilkan karakteristik tekstur (Achmad et al., 2021).

Adapun *Local Binary Pattern* (LBP) adalah salah satu metode yang digunakan untuk memperoleh tekstur sebagai dasar klasifikasi. Keunggulan metode ini terletak pada kompleksitas dan komputasi yang rendah (Fuad Mahrus Fathoni, 2024). Algoritma ekstraksi LBP secara umum terdiri dari dua langkah utama, yaitu ambang batas dan pengkodean. Penelitian oleh (Hafizd et al., 2020) menggunakan metode LBP dan GLRLM untuk mengekstraksi ciri tekstur dari citra bahan kulit hewan. Ciri-ciri tersebut kemudian diklasifikasikan menggunakan *Neural Network* untuk mengidentifikasi jenis kulit hewan (sapi, babi, domba, kambing, kanguru). Hasil penelitian menunjukkan bahwa metode ini mencapai akurasi identifikasi sebesar 60%. Penelitian oleh (Kanugroho et al., 2022) bertujuan untuk mengenali tekstur batik pada citra digital.

Metode yang digunakan adalah praproses citra, ekstraksi ciri tekstur LBP dengan nilai LBP yang dinormalisasi, dan klasifikasi KNN dengan $K = 5$. Hasil penelitian menunjukkan bahwa metode ini mencapai akurasi pengenalan

tekstur batik sebesar 65%. Penelitian yang membandingkan ekstraksi fitur GLCM dan LBP telah dilakukan oleh (Neneng et al., 2021). Dalam penelitian tersebut, ciri tekstur yang digunakan meliputi ASM, IDM, entropi, kontras, dan korelasi. Hasil klasifikasi citra daging kambing, kerbau, dan kuda dengan metode GLCM menunjukkan akurasi sebesar 75,6%, sedangkan metode LBP menghasilkan akurasi sebesar 85,6%. Oleh karena itu, metode ekstraksi fitur LBP lebih direkomendasikan untuk klasifikasi. Penelitian lainnya dilakukan oleh (Prasaja, 2022) yang membandingkan antara metode *Gray Level Co-Occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP) untuk ekstraksi fitur terbukti dalam berbagai studi penelitian. GLCM dan LBP digunakan dalam analisis tekstur kayu untuk mengklasifikasikan jenis kayu yang berbeda, mencapai akurasi 90% dengan GLCM dan akurasi 70% dengan LBP.

Selanjutnya terdapat jurnal yang berjudul *Klasifikasi Jenis Buah Apel Dengan Metode K- Nearest Neighbour* yang disusun oleh Novan Wijaya, Anugrah Ridwan (Ilmi et al., 2021). Menggunakan ekstraksi warna HSV untuk melihat tingkat kecerahan suatu warna dari objek apel, menggunakan 800 data citra. Hasil evaluasi yang didapat secara keseluruhan yaitu nilai rata-rata *Precision* yang didapat sebesar 94%, *Recall* sebesar 100% dan *Accuracy* sebesar 94%. Sementara itu (Muktianto & Indriyani, 2022) melakukan penelitian menggunakan metode *Watershed* berdasarkan segmentasi warna *Hue*, *Saturation*, dan *Value* (HSV) untuk mengidentifikasi warna kulit pada citra buah pisang kelas sangat matang, yang menghasilkan tingkat akurasi mencapai 65%.

Menggabungkan fitur warna dan tekstur bisa menjadi pendekatan yang efektif untuk mengatasi kompleksitas variasi penyakit dan kondisi citra. Citra diwakili sebagai kombinasi intensitas dari tiga warna dasar, yang menghasilkan spektrum warna yang luas. Model warna HSV menggambarkan warna dalam tiga dimensi: *Hue* (H), yang menunjukkan jenis warna dalam bentuk sudut; *Saturation* (S), yang mengukur seberapa cerah warna; dan *Value* (V), yang menentukan tingkat kecerahan atau kegelapan. Model ini lebih mudah dipahami untuk menggambarkan karakteristik warna seperti kejernihan dan kecerahan.

Berdasarkan latar belakang yang telah diuraikan maka akan dilakukan penelitian dengan judul implementasi ekstraksi fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP) serta menggunakan ekstraksi warna menggunakan *Hue Saturation Value* (HSV) untuk klasifikasi penyakit daun tomat.

1.2 Rumusan Masalah

Adapun rumusan masalah dalam penelitian ini yaitu bagaimana hasil performa ekstraksi fitur menggunakan *Gray Level Co-occurrence Matrix* (GLCM), *Local Binary Pattern* (LBP), dan *Hue Saturation Value* (HSV) pada objek penyakit daun tomat baik secara terpisah dan dalam penggabungan?

1.3 Batasan Masalah

1. Data yang digunakan akan terdiri dari dataset citra daun tomat yang sudah berlabel dengan kondisi penyakit yang sesuai yang diambil dari website Kaggle dengan nama dataset *New Plant Diseases*.
2. Penelitian ini akan membatasi deteksi pada 7 jenis kelas penyakit daun tomat yaitu *healthy*, *bacterial spot*, *late blight*, *leaf mold*, *spotted spider mite*, *target spot*, dan *yellow leaf curl virus*.
3. Pengembangan sistem deteksi akan dilakukan berdasarkan pengolahan citra digital menggunakan teknik ekstraksi fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP) serta ekstraksi fitur warna menggunakan *Hue Saturation Value* (HSV).

1.4 Tujuan Penelitian

Untuk mengetahui hasil ekstraksi fitur citra menggunakan fitur tekstur *Gray Level Co-occurrence Matrix* (GLCM) dan *Local Binary Pattern* (LBP) serta ekstraksi fitur warna menggunakan *Hue Saturation Value* (HSV) pada objek penyakit daun tomat baik secara terpisah dan penggabungan.

1.5 Manfaat Penelitian

1. Memberikan solusi yang efektif dan efisien untuk mendeteksi penyakit pada tanaman tomat, yang dapat membantu petani mengatasi masalah penyakit tanaman dan meningkatkan hasil panen mereka.
2. Mengurangi kebutuhan akan intervensi pestisida yang berlebihan

dengan mendeteksi penyakit secara dini, yang pada gilirannya dapat mengurangi dampak negatif terhadap lingkungan dan kesehatan manusia.

3. Mendorong pengembangan teknologi otomatisasi dalam bidang pertanian, yang dapat meningkatkan produktivitas dan keberlanjutan pertanian secara keseluruhan.

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

a. Tanaman Tomat

Tomat (*Solanum lycopersicum*) merupakan salah satu makanan yang dikonsumsi masyarakat secara mentah atau belum diolah. Buah tomat merupakan sumber protein, lemak, vitamin dan mineral, tetapi juga mengandung zat bioaktif seperti likopen, vitamin A, vitamin C, solanin, saponin, asam folat, asam malat, asam sitrat, bioflavonoid (termasuk likopen, α -). dan β -karoten dan histamin (Hadi, 2023), Data produksi tomat di Indonesia pada tahun 2018 sebesar 976.772 ton dan pada tahun 2019 meningkat menjadi 1.020.331 ton. Indonesia terus meningkat setiap tahun, konsumsi tomat oleh sektor rumah tangga tahun 2021 adalah mencapai 677,97 ribu ton, naik sebesar 6,93% (43,96 ribu ton) dari tahun 2020 (Badan Pusat Statistik, 2022). Di Indonesia tanaman tomat banyak dibudidayakan karena nilai harga jual tomat yang cukup stabil, banyak dikonsumsi masyarakat dan tidak terlepas juga dari iklim yang mendukung. Berdampingan dengan bertambahnya jumlah penduduk dan tingkat kesadaran masyarakat yang semakin tinggi tentang pentingnya kesehatan, berdasarkan data dari Kementerian Pertanian Republik Indonesia jumlah konsumsi tomat pada tahun 2017-2021 selalu meningkat 5,32% per tahunnya.

Walaupun dalam pembudidayaan tanaman tomat tergolong mudah, tomat juga rentan terserang penyakit yang dipengaruhi oleh bakteri, jamur, virus dan serangga atau hama.

b. Penyakit Daun Tomat


Tomat yang terserang penyakit mengalami perubahan warna dan bentuk pada seluruh bagian tanaman tomat, seperti daun, batang, akar, hingga ke buahnya, akan tetapi yang sering menjadi acuan dalam melihat gejala penyakit pada tanaman tomat adalah melalui daun.

Terdapat beberapa jenis penyakit pada tanaman tomat yaitu penyakit *bacterial wilt*, *buckeye rot*, *powdery mildew*, *gray leaf spot*, *southern blight*, *yellow leaf curl virus*, *potato virus*, *tomato mozaik virus*, *bercak daun* (*Septoria leaf spot*), *bacterial spot target spot*, *bercak kering alternaria* (*early blight*), *busuk daun* (*late blight*), *daun berjamur* (*leaf mold*), *bercak daun akibat gigitan serangga* (*two-spot spider mite*), *gray mold*, *target spot*, dan sebagainya. Rata-rata tanaman tomat di Indonesia terserang penyakit busuk daun dan bercak daun, namun dalam membedakan kedua penyakit tersebut sangat sulit jika dilakukan secara kasat mata. Akibatnya, petani sering keliru dalam menggunakan obat pada saat mengendalikan penyakit sehingga mengakibatkan kerusakan tanaman tomat dan petani mengalami kerugian karena gagal panen (Putri, 2021).

c. *Gray Level Co-occurrence Matrix (GLCM)*

Langkah pertama dalam melakukan ekstraksi fitur menggunakan metode GLCM adalah melakukan pembentukan matriks kookurensi ekstraksi berdasarkan sudut dan derajat yang telah ditentukan (Lamasigi et al., 2022). *Gray Level Co-occurrence Matrix (GLCM)* adalah matriks yang merepresentasikan hubungan ketetanggaan antar pixel dalam citra pada berbagai arah orientasi θ 0° , 45° , 90° , dan 135° dan jarak d , Matriks GLCM dari suatu citra $f(x,y)$ adalah matriks dua dimensi (x,y) dimana setiap elemen dari matriks mewakili probabilitas terjadinya bersama tingkat intensitas x dan y pada jarak d tertentu dan sudut θ (Mungki Astiningrum et al., 2020).

Nilai fitur yang dapat digunakan pada GLCM antara lain adalah *contrast*, *correlation*, *energy* dan *homogeneity* (Fikriah et al., 2022).



Gambar 2.1 *Gray Level Co-Occurrence Matrix* dengan arah 0° , 45° , 90° , 135°

(Sumber : Mungki Astiningrum 2020)

Langkah-langkah ekstraksi fitur GLCM adalah sebagai berikut:

1. Mengubah citra RGB menjadi citra berskala keabuan.
2. Membentuk matriks *co-occurrence* dan dilanjutkan dengan menentukan hubungan spasial antara piksel referensi dan piksel tetangga berdasarkan sudut θ dan jarak d .
3. Membentuk matriks simetris dengan menambahkan *matrix co-occurrence* dengan matriks transposenya.
4. Melakukan normalisasi terhadap matriks simetris dengan menghitung probabilitas setiap elemen matriks.

Nilai fitur yang dapat digunakan pada *Gray Level Co-occurrence Matrix* (GLCM) antara lain adalah *contrast*, *correlation*, *energy* dan *homogeneity* (Fikriah et al., 2022).

a. *Contrast*

Contrast dalam fitur GLCM menunjukkan ukuran penyebaran elemen – elemen matriks ciri. Jika letaknya jauh dari diagonal utama, nilai *contrast* besar. Pada persamaan 2.4 dijelaskan persamaan untuk menghitung nilai *contrast* yaitu:

$$contrast = \sum_{x,y} (x - y)^2 p(x, y) \quad (2.4)$$

Keterangan :

x, y = Indeks baris dan kolom dalam matriks GLCM, yang menunjukkan pasangan nilai intensitas piksel.

$p(x, y)$ = Nilai probabilitas atau frekuensi relatif dari pasangan nilai intensitas x dan y dalam citra.

$(x - y)^2$ = Mengukur kuadrat perbedaan antara intensitas x dan y . Nilai ini semakin besar jika x dan y berbeda jauh, yang berkontribusi terhadap nilai kontras yang tinggi.

b. *Correlation*

Correlation menyatakan ukuran ketergantungan linear derajat keabuan citra sehingga dapat memberikan petunjuk adanya struktur linear dalam citra. Pada persamaan 2.5 dijelaskan persamaan untuk menghitung nilai *correlation*, yaitu:

$$correlation = \sum_{x,y} \frac{(n - \mu_x)(y - \mu_y)p(x, y)}{\sigma_x \sigma_y} \quad (2.5)$$

Keterangan :

x,y = Indeks baris dan kolom dalam matriks GLCM.

$p(x,y)$ = Nilai probabilitas atau frekuensi relatif dari pasangan nilai intensitas x dan y dalam citra.

μ_x = Rata-rata nilai intensitas untuk indeks x

μ_y = Rata-rata nilai intensitas untuk indeks y

σ_x = Standar deviasi untuk nilai intensitas x

σ_y = Standar deviasi untuk nilai intensitas y

$(x - \mu_x)(y - \mu_y)$ = Ukur penyimpangan rata-rata yang menunjukkan seberapa baik pasangan nilai x dan y terhubung secara linear

c. *Homogeneity*

Homogeneity menunjukkan kehomogenan variasi intensitas dalam citra, *homogeneity* akan bernilai tinggi jika semua piksel mempunyai nilai yang seragam. Pada persamaan 2.6 dijelaskan persamaan untuk menghitung nilai *homogeneity*, yaitu:

$$\text{homogeneity} = \sum_{x,y} \frac{p(x,y)}{1+|x-y|} \quad (2.6)$$

Keterangan :

x,y = Indeks baris dan kolom dalam matriks GLCM, yang menunjukkan pasangan nilai intensitas piksel.

$p(x,y)$ = Nilai probabilitas atau frekuensi relatif dari pasangan nilai intensitas x dan y dalam citra.

$|x - y|$ = Mengukur perbedaan absolut antara x dan y . Jika x dan y mendekati nilai yang sama, nilai ini kecil dan *homogeneity* akan tinggi

d. *Energy*

Energy mengukur tentang keseragaman atau *angular second moment*, *energy* akan bernilai tinggi ketika nilai piksel mirip dengan piksel yang lain, sebaliknya akan bernilai kecil yang berarti nilai dari GLCM normalisasi adalah heterogen. Pada persamaan 2.7 dijelaskan persamaan untuk menghitung nilai *energy*, yaitu:

$$energy = \sum_{x,y} p(x,y)^2 \quad (2.7)$$

Keterangan :


x,y = Indeks baris dan kolom dalam matriks GLCM, yang menunjukkan pasangan nilai intensitas piksel.

$p(x,y)$ = Nilai probabilitas atau frekuensi relatif dari pasangan nilai intensitas x dan y dalam citra.

$p(x,y)^2$ = Mengukur kuadrat dari nilai probabilitas.

d. *Local Binary Pattern (LBP)*

Metode *Local Binary Pattern (LBP)* 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 invariant terhadap pencahayaan yang berbeda, Metode *Local Binary Pattern (LBP)* merupakan teknik merubah piksel pada citra menjadi nilai desimal. metode ini berguna sebagai pengolah informasi mengenai struktur lokal yang terdapat pada sekitar piksel gambar (Ananta Dwi Prayoga Alwy et al., 2023). Metode LBP akan merubah piksel dari gambar menjadi angka desimal, yang disebut dengan istilah LBP atau kode LBP yang akan mengkodekan struktur lokal.



Gambar 2.2 Ekstraksi Fitur *Local Binary Pattern*

(Sumber : Ananta Dwi Prayoga 2023)

Dari seluruh piksel yang terdapat pada citra, dilakukan perhitungan untuk mendapatkan citra LBP, proses konversi dilakukan dengan menghitung apakah 7 nilai di sekitar piksel center memiliki nilai lebih dari piksel center atau tidak, apabila iya maka nilai pada piksel tersebut adalah 1, jika tidak maka nilai pada piksel tersebut adalah 0 (Fuad

Mahrus Fathoni, 2024). Setelah itu dilakukan pengambilan nilai dari ke 8 piksel tersebut secara urut arah jarum jam ataupun sebaliknya sehingga diperoleh nilai 8 bit biner yang diubah menjadi desimal untuk menggantikan nilai piksel yang ada pada piksel center (Ananta Dwi Prayoga Alwy et al., 2023). Setelah diperoleh citra LBP maka dapat dilakukan pengambilan 5 nilai fitur LBP berupa *Mean*, *Variance*, *Skewness*, *Kurtosis*, dan *Entropy* (Sanjaya et al., 2020).

$$\text{mean } (\mu) = \sum_n f_n p(f_n) \quad (2.8)$$

$$\text{variance } (\sigma) = \sum_n (f_n - \mu)^2 P(f_n) \quad (2.9)$$

$$\text{skewness } (a_3) = \frac{1}{\sigma^3} \sum_n (f_n - \mu)^3 P(f_n) \quad (2.10)$$

$$\text{kurtosis } (a_4) = \frac{1}{\sigma^4} \sum_n (f_n - \mu)^4 P(f_n) - 3 \quad (2.11)$$

$$\text{entropy } (H) = - \sum_n P(f_n)^2 \log P(f_n) \quad (2.12)$$

Keterangan :

n = total elemen dalam dataset

P = probabilitas

f = nilai individu dalam dataset

f_n = nilai spesifik dari variabel acak pada posisi n

Mean adalah nilai rata-rata dari semua nilai

Variance mengukur seberapa jauh nilai dalam data menyebar dari mean.

Skewness mengukur simetri distribusi data.

Kurtosis mengukur ketinggian dan ketebalan data.

Entropy mengukur tingkat ketidakpastian atau keragaman dalam data.

e. *Hue Saturation Value (HSV)*

HSV memiliki 3 karakteristik pokok dari warna antara lain :

- a. *Hue* adalah warna sebenarnya, seperti merah, violet, dan kuning dan untuk menentukan kemerahan (*redness*), kehijauan (*greenness*).
- b. *Saturation* adalah kemurnian atau kekuatan warna.
- c. *Value* kecerahan dari warna. Nilainya berkisar antara 0-100 %.

Untuk mentransformasi dari RGB ke HSV, harus menentukan koordinat-koordinat R, G, B yang berurutan seperti merah, hijau, biru dalam ruang warna RGB, dengan max adalah nilai maksimum dari nilai

red, green, blue, dan *min* adalah nilai minimum dari nilai *red, green, blue* (Wijaya & Ridwan, 2019). Untuk memperoleh sudut *hue*[0,360] yang tepat untuk ruang warna HSV, menggunakan rumus seperti berikut:

$$V = \text{Maximum}(R, G, B) \quad (2.13)$$

$$S = \begin{cases} 0, & \text{jika } V=0 \\ \frac{\text{Maximum}(R,G,B) - \text{Minimum}(R,G,B)}{\text{Maximum}(R,G,B)} & \text{jika } V>0 \end{cases} \quad (2.14)$$

$$H = \begin{cases} 0, & \text{jika } \text{Max} = \text{Min} \\ \frac{60 \times (G-B)}{\text{Max}-\text{Min}}, & \text{jika } V = R \\ 60 \times \left[2 + \frac{B-R}{\text{Max}-\text{Min}} \right] & \text{jika } V = G \\ 60 \times \left[4 + \frac{R-G}{\text{Max}-\text{Min}} \right] & \text{jika } V = B \end{cases} \quad (2.15)$$

Keterangan :

$V = Value$ mewakili tingkat kecerahan atau intensitas.

$S = Saturation$ mewakili saturasi atau kejernihan warna.

$H = Hue$ menunjukkan warna dominan pada skala derajat.

$R = Red$ mewakili intensitas warna merah.

$G = Green$ mewakili intensitas warna hijau.

$B = Blue$ menunjukkan intensitas warna biru.

Proses segmentasi warna merupakan metode segmentasi berbasis daerah yang menganalisis nilai warna dari setiap piksel dalam citra, kemudian membagi citra tersebut berdasarkan fitur yang diinginkan. Pada segmentasi menggunakan metode deteksi warna HSV, dipilih sampel piksel sebagai acuan warna untuk membentuk segmen yang diharapkan. Karena citra digital umumnya menggunakan model warna RGB sebagai standar, langkah pertama dalam metode ini adalah mengonversi model warna RGB ke HSV (Ellif et al., 2021).

Untuk mengklasifikasikan fitur warna HSV, digunakan beberapa nilai dari masing-masing *channel* H, S, dan V. Nilai yang digunakan antara lain nilai Mean, Standar Deviasi, dan Skewness. Tujuan dari perhitungan nilai fitur ini adalah untuk menemukan citra dengan komposisi warna yang mirip untuk pengklasifikasian.

$$\text{Mean}(\mu) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N P_{ij} \quad (2.16)$$


$$\text{Standar Deviasi } (\sigma) = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (P_{ij}-\mu)^2} \quad (2.17)$$

$$\text{Skewness } (\theta) = \sqrt[3]{\left(\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (P_{ij}-\mu)^3\right)} \quad (2.18)$$

f. Klasifikasi

Metode klasifikasi mengambil variabel dari kelompok data yang sudah ada. Tujuan klasifikasi adalah untuk memprediksi kelas objek yang tidak diketahui sebelumnya. Ini terdiri dari tiga tahap: pembangunan model, penerapan model, dan evaluasi. Setelah pembangunan model, data latih digunakan untuk membangun model. Setelah itu, data latih diterapkan untuk menentukan kelas objek atau data baru. Selanjutnya, data dievaluasi untuk mengetahui seberapa akurat pembangunan dan penerapan model pada data baru. Proses klasifikasi terdiri dari dua tahap: pelatihan dan pengujian. Fase pelatihan adalah tahap di mana data dikumpulkan (Nasution et al., 2019). Adapun metode klasifikasi yang akan digunakan pada penelitian ini yaitu *Deep Neural Network* (DNN) merupakan salah satu jenis model machine learning yang terdiri dari banyak lapisan yang saling terhubung, dimana setiap lapisan terdiri dari banyak unit komputasi yang disebut neuron. Dalam *Deep Neural Network* (DNN), data masukan diproses secara berurutan melalui setiap lapisan dimana setiap lapisan melakukan transformasi pada data masukan dan menghasilkan representasi semantik yang semakin kompleks (Irpanudin et al., 2023).

Arsitektur *Deep Neural Network* (DNN) Pada arsitektur DNN, terdapat tiga jenis lapisan utama, yaitu lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan keluaran (*output layer*).



Gambar 2.3 Deep Neural Network architecture diagram
Sumber : (Simani et al., 2023)

Setiap lapisan terdiri dari satu atau lebih unit pemrosesan yang disebut sebagai neuron atau node. Neuron dalam lapisan masukan menerima input data dan meneruskannya ke lapisan tersembunyi. Lapisan tersembunyi kemudian melakukan pemrosesan lebih lanjut terhadap input yang diterima dan meneruskannya ke lapisan berikutnya. Lapisan keluaran menghasilkan output akhir dari jaringan (Irpanudin et al., 2023).

g. *Deep Learning*

Semenjak tahun 1950-an, salah satu cabang dari AI yang disebut dengan ML telah berkembang cukup pesat dengan implementasi di beberapa bidang. NN adalah salah satu implementasi dari ML, sedangkan DL merupakan salah satu implementasi dari NN (Muhammad Haris Diponegoro et al., 2021). DL, yang mulai populer digunakan sejak tahun 2006, menggunakan mekanisme deep architecture of learning atau pendekatan *hierarchical learning*. *Learning* atau pembelajaran dalam hal ini adalah sebuah prosedur yang berisi proses estimasi parameter-parameter suatu model sehingga model yang dikembangkan (algoritme) dapat menyelesaikan suatu tugas atau permasalahan tertentu.

DL menggunakan beberapa lapisan (*layers*) di antara lapisan masukan (*input layer*) dan lapisan keluaran (*output layer*). Arsitektur tersebut dapat digunakan untuk melakukan pemrosesan nonlinier dengan beberapa tahap yang hasilnya dapat digunakan untuk *feature learning* dan klasifikasi pola (*pattern classification*). Jumlah lapisan dalam DL yang

bervariasi dapat digunakan untuk melakukan abstraksi dengan tingkat yang berbeda-beda

h. Confusion Matrix

Pengukuran kinerja algoritma pengklasifikasi dilakukan dengan menggunakan *confusion matrix*. Dimana *confusion matrix* diperoleh dari proses validasi. Mengevaluasi kinerja algoritma klasifikasi umumnya menggunakan hasil keseluruhan pada pengujian dataset. Sebuah matrik dari prediksi yang akan dibandingkan dengan kelas yang asli dari masukan atau dengan kata lain berisi informasi nilai aktual dan prediksi pada klasifikasi. *Confusion matrix* dapat membantu menunjukkan rincian kinerja pengklasifikasi dengan memberikan informasi jumlah fitur suatu kelas yang diklasifikasikan dengan tepat dan tidak tepat.

Tabel 2.1 *Confusion Matrix*

Nilai Aktual	Nilai Prediksi		
		Positif (1)	Negatif (0)
	Positif (1)	TP (<i>True Positif</i>)	FP (<i>False Positif</i>)
	Negatif (0)	FN (<i>False Negatif</i>)	TN (<i>True Negatif</i>)

Keterangan:

- *True Positive* (TP), jumlah dokumen dari kelas 1 yang benar dan diklasifikasikan sebagai kelas 1.
- *True Negative* (TN), jumlah dokumen dari kelas 0 yang benar diklasifikasikan sebagai kelas 0.
- *False Positive* (FP), jumlah dokumen dari kelas 0 yang salah diklasifikasikan sebagai kelas 1.
- *False Negative* (FN), jumlah dokumen dari kelas 1 yang salah diklasifikasikan sebagai kelas 0. Evaluasi dan validasi hasil dihitung menggunakan rumus akurasi, *precision*, dan *recall* berikut ini:

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (2.19)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2.20)$$

$$Recall = \frac{TP}{TP+FN} \quad (2.21)$$

Nilai *precision* adalah nilai sensitivitas atau nilai ketepatan sistem antara informasi yang diberikan oleh sistem untuk menunjukkan secara benar data kelas negatif atau kelas positif. Sedangkan nilai *recall* adalah nilai yang menunjukkan tingkat keberhasilan atau spesifisitas untuk mengetahui kembali sebuah informasi secara benar tentang data yang kelas negatif atau kelas positif. Sedangkan nilai akurasi adalah nilai rasio data yang benar terdeteksi di dalam data pengujian. Dengan kata lain, akurasi adalah nilai yang menunjukkan tingkat kedekatan antara nilai prediksi sistem dengan nilai prediksi manusia (Azhari et al., 2021).

2.2 Penelitian Terkait

Dalam persiapan penelitian ini, penting untuk merujuk pada beberapa penelitian sebelumnya sebagai landasan dan wawasan. Hal ini bertujuan untuk memperoleh informasi dan ide-ide yang dapat dikembangkan dalam penelitian ini. Untuk itu, telah dikumpulkan sejumlah referensi dari penelitian-penelitian terdahulu yang relevan dengan permasalahan yang dibahas dalam penelitian ini.

Tabel 2.2 Penelitian Terkait

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
1	Fuad Mahrus Fathoni 2024	Klasifikasi Penyakit Daun Tomat Menggunakan <i>Algoritma K- NN</i> Berdasarkan Ekstraksi Fitur GLCM dan LBP	Hasil dari penelitian ini nilai evaluasi akurasi tertinggi sebesar 86,8% waktu melakukan klasifikasi menggunakan nilai K=9 dan K=10, dengan nilai presisi	Yang menjadi pembeda dalam penelitian ini yaitu penelitian ini menggunakan algoritma <i>K- Nearest Neighbor</i>	persamaannya adalah menggunakan ekstraksi fitur dan GLCM dan LBP dengan kasus penyakit daun tomat

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
			<p>= 40,6% dan <i>recall</i> 49,2% waktu klasifikasi menggunakan nilai $K = 9$, serta presisi = 49,7% dan <i>recall</i> 49,3% waktu klasifikasi menggunakan nilai $K = 10$. Selain itu juga diperoleh nilai evaluasi paling rendah waktu melakukan klasifikasi menggunakan nilai $K=1$ dan $K=2$ dengan nilai akurasi sebesar 85,1% dan presisi sebesar 44% dan <i>recall</i> sebesar 43,7%.</p>		
2	Neneng , Ajeng Savitri Puspaningrum , Ahmad Ari Aldino 2020	Perbandingan Hasil Klasifikasi Jenis Daging Menggunakan Ekstraksi Ciri Tekstur <i>Gray Level Co-occurrence</i>	Hasil akurasi klasifikasi citra daging kambing, kerbau, dan kuda menggunakan metode GLCM adalah sebesar 75,6%. Sedangkan hasil akurasi	Yang menjadi perbedaan dalam penelitian ini yaitu penelitian ini menggunakan objek jenis daging	Yang menjadi persamaannya adalah menggunakan ekstraksi fitur GLCM dan LBP

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
		<i>Matrices</i> (GLCM) Dan <i>Local Binary Pattern</i> (LBP)	klasifikasi menggunakan metode LBP adalah sebesar 85,6%. Dengan demikian, metode ekstraksi ciri tekstur LBP lebih direkomendasikan untuk klasifikasi jenis daging menggunakan ciri tekstur.		
3	Ananta Dwi Prayoga Alwy, M. Syahid Nur Wahid, Bukhari Naufal Nur Ag, 4M. Miftach Fakhri 2023	Klasifikasi Penyakit Pada Padi Dengan Ekstraksi Fitur LBP dan GLCM	Proses dan metode yang diusulkan yaitu Akuisisi citra, <i>preprocessing</i> , segmentasi dengan metode konversi nilai menjadi biner, operasi morfologi dengan menggunakan Area Open, ekstraksi fitur menggunakan LBP dan GLCM, dan terakhir tahap klasifikasi dengan <i>Decision Tree</i> . Berdasarkan hasil pengujian, diperoleh tingkat	Yang menjadi perbedaan dalam penelitian ini yaitu penelitian ini menggunakan objek penyakit pada padi	Persamaannya adalah sama-sama menggunakan ekstraksi fitur LBP dan GLCM

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
			akurasi sebesar 90%		
4	Sofia Saidah , Rita Purnamasari , Aulia Novria Bainuri, Gloria Shekinah Florensia Wahid, 2020	Analisis Perbandingan Metode LBP dan CLBP pada Sistem Pengenalan Individu Melalui Iris Mata	hasil penelitian diperoleh bahwa metode CLBP menghasilkan akurasi tertinggi sebesar 89,71%, sementara metode LBP menghasilkan akurasi 87,43%.	Yang menjadi perbedaan dalam penelitian ini yaitu penelitian ini menggunakan kasus pengenalan individu melalui iris mata	Persamaannya adalah sama-sama menggunakan ekstraksi fitur LBP
5	Maulana Hafizd , Mayanda Mega Santoni , Anita Muliawati 2020	Level <i>Run Length Matrix</i> Untuk Identifikasi Citra Bahan Kulit Hewan	Dalam penelitian ini digunakan citra bahan kulit hewan yang memiliki lima kategori, yaitu kulit sapi, babi, domba, kambing, dan kanguru. Tingkat akurasi yang didapatkan dari implementasi metode LBP dan GLRLM untuk identifikasi citra bahan kulit hewan sebesar 60%.	Yang menjadi perbedaan dalam penelitian ini yaitu penelitian ini menggunakan objek citra bahan kulit hewan	Persamaannya adalah sama-sama menggunakan ekstraksi fitur dengan LBP
6	Puji Laksono 1 ,	Deteksi Tumor	Hasil yang	Yang menjadi	Yang menjadi

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
	Harliana , Tito Prabowo, 2023	Otak Melalui Penerapan GLCM dan <i>Naïve Bayes Classification</i>	didapatkan dari penelitian ini yakni akurasi yang paling baik didapatkan algoritma <i>naïve bayes</i> adalah 80% yang dimiliki pada skenario pertama dengan data testing 20% dan data training 80%. Dibangun sebuah web yang mengimplementasi kan ekstraksi fitur glcm dan algoritma <i>naïve bayes</i> untuk dimanfaatkan oleh para tenaga medis dalam mendiagnosa pasien tumor otak dengan efisien dan objektif	pembedaan dalam penelitian ini yaitu penelitian ini menggunakan algoritma <i>Naïve Bayes</i> dengan kasus deteksi tumor otak sedangkan penelitian yang akan dibuat yaitu untuk klasifikasi penyakit daun tomat.	Persamaan sama-sama menggunakan ekstraksi GLCM

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
7	Ananta Dwi Prayoga Alwy, M. Syahid Nur Wahid, Bukhari Naufal Nur Ag, M. Miftach Fakhri, 2024	Klasifikasi Penyakit Pada Padi Dengan Ekstraksi Fitur LBP dan GLCM	Dalam Penelitian ini menggunakan <i>Decision Tree</i> sebagai Klasifikasi Penyakit Pada padi. Dengan membagi setiap <i>record-record</i> atau hasil uji yang telah dilakukan secara continue penentuan atau pengambilan keputusan untuk menentukan Penyakit Pada Padi mendapatkan akurasi sebesar 91% dari 36 data uji yang telah dieksekusi.	Yang menjadi pembeda dalam penelitian ini yaitu penelitian ini menggunakan algoritma <i>Decision Tree</i> untuk klasifikasi penyakit daun padi sedangkan penelitian yang dibuat ini menggunakan implementasi kasus penyakit daun tomat.	Yang menjadi Persamaan sama - sama menggunakan ekstraksi fitur GLCM dan LBP
8	Muhammad Tegar Kanugroho, Muh. Arif Rahman, Randy Cahya Wihandika 2022	Klasifikasi Batik dengan Ekstraksi Fitur Tekstur <i>Local Binary Pattern</i> dan Metode K- <i>Nearest Neighbor</i>	Proses penelitian pada batik diawali dengan pra-proses, kemudian ekstraksi fitur tekstur pada citra dengan metode <i>Local Binary Pattern</i> (LBP) dan dilanjutkan dengan klasifikasi oleh K-	Yang menjadi pembeda dalam penelitian ini yaitu penelitian ini menggunakan objek batik sedangkan penelitian yang akan dibuat menggunakan kasus citra	Yang menjadi Persamaan sama - sama menggunakan ekstraksi LBP

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
			<p><i>Nearest Neighbor</i>(KNN). Pada penelitian ini menggunakan nilai LBP yang dinormalisasi. Pada data yang dinormalisasi, hasil terbaik menggunakan K-Nearest Neighbor Dengan tetangga (K) = 5 mendapatkan hasil akurasi sebesar 65%</p>	penyakit daun tomat	
9	Mizanul Ridho Aohana , Ratu Nisful Laily Hidayah , Melki Jonathan Andara , Nadya Amara, Fitri Bimantoro5 2024	Review Komprehensif : Ekstraksi Fitur GLCM, GLRLM, dan LBP untuk Pendeteksian Korosi	Hasil eksperimen menunjukkan keberhasilan metode ini, dengan tingkat akurasi berturut-turut sebesar 74,02%, 79,61%, dan 84,36%.	Yang menjadi pembeda dalam penelitian ini yaitu penelitian ini Melibatkan model pendeteksi berbasis MLP	Yang menjadi Persamaan sama - sama menggunakan ekstraksi GLCM dan LBP
10	Fari Katul Fikriah , M. Burhanis	Naïve Bayes untuk Klasifikasi	Hasil peneliti menggunakan algoritma <i>Naïve</i>	Yang menjadi pembeda dalam penelitian ini	persamaannya adalah menggunakan

No	Nama/ Tahun	Judul	Hasil	Perbedaan	Persamaan
	Sulthan, Nailatul Mujahidah, Moh. Khoirur Roziqin, 2022	Penyakit Daun Bawang Merah Berdasarkan Ekstraksi Fitur <i>Gray Level</i> <i>Co-</i> <i>occurrence</i> <i>Matrix</i> (GLCM)	<i>Bayes</i> yang melibatkan dua kelas yaitu ringan dan berat dapat diambil kesimpulan untuk kasus pada penelitian ini memiliki hasil tingkat akurasi sebanyak 84%. Hasil tersebut didapatkan dengan menggunakan ekstraksi data menggunakan metode GLCM dengan fitur <i>contrast</i> , <i>Correlation</i> , <i>Energy</i> , <i>Homogeneity</i> dengan rata-rata sudut dari 0°, 45°, 90°, dan 135°	yaitu penelitian ini menggunakan algoritma <i>Naive</i> <i>Bayes</i> untuk klasifikasi penyakit daun bawang dan hanya menggunakan ekstraksi fitur GLCM saja.	ekstraksi GLCM

DAFTAR PUSTAKA

- Aohana, M. R., Hidayah, R. N. L., Andara, M. J., Amara, N., & Bimantoro, F. (2024). Review Komprehensif: Ekstraksi Fitur GLCM, GLRLM, dan LBP untuk Pendeteksian Korosi. *Seminar Nasional Teknologi & Sains*, 3(1), 82–90. <https://doi.org/10.29407/stains.v3i1.4352>
- Desiani, A., Zayanti, D. A., Primartha, R., Efriliyanti, F., & Andriani, N. A. C. (2021). Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 7(2), 255. <https://doi.org/10.26418/jp.v7i2.47205>
- Ellif, Sitorus, S. H., & Hidayati, R. (2021). Naïve Bayes 1. *Coding : Jurnal Komputer Dan Aplikasi*, 09(01), 66–75.
- Fauzi, A. (2022). Pengurangan Derau (Noise) pada Citra Paper Dokumen menggunakan Metode Gaussian Filter dan Median Filter. *KAKIFIKOM (Kumpulan Artikel Karya Ilmiah Fakultas Ilmu Komputer)*, 04(01), 7–15. <https://doi.org/10.54367/kakifikom.v4i1.1871>
- Fikriah, F. K., Burhanis Sulthan, M., Mujahidah, N., & Khoirur Roziqin, M. (2022). Naïve Bayes untuk Klasifikasi Penyakit Daun Bawang Merah Berdasarkan Ekstraksi Fitur Gray Level Cooccurrence Matrix (GLCM). *Jurnal Komtika (Komputasi Dan Informatika)*, 6(2), 133–141. <https://doi.org/10.31603/komtika.v6i2.7925>
- Fuad Mahrus Fathoni. (2024). Klasifikasi Penyakit Daun Tomat Menggunakan Algoritma K-NN Berdasarkan Ekstraksi Fitur GLCM dan LBP. *Jurnal Teknik Informatika Dan Teknologi Informasi*, 4(1), 39–50. <https://doi.org/10.55606/jutiti.v4i1.34>
- Hadi, A. S. (2023). Khasiat Buah Tomat (*Solanum lycopersicum*) Berpotensi Sebagai Obat Berbagai Jenis Penyakit. *Empiris: Journal of Progressive Science and Mathematics*, 1(1), 7–15. <https://doi.org/10.59698/empiris.v1i1.36>
- Hafizd, M., Santoni, M. M., & Muliawati, A. (2020). Level Run Length Matrix Untuk Identifikasi Citra Bahan Kulit Hewan. *Seinasi-Kesi*, 3(1), 173–180

- Irpanudin, Reka, Nur Anggraeni, R., Pratama, P., Sujjada, A., & Fergina, A. (2023). Prediksi Penyakit Jantung Menggunakan Metode Deep Neural Network dengan Memanfaatkan Internet of Things. *Jurnal Informasi Dan Teknologi*, 5, 45–55. <https://doi.org/10.37034/jidt.v5i2.330>
- Kanugroho, M. T., Rahman, M. A., & Wihandika, R. C. (2022). *Klasifikasi Batik dengan Ekstraksi Fitur Tekstur Local Binary Pattern dan Metode K-Nearest Neighbor*. 6(10), 4788–4794. <http://j-ptiik.ub.ac.id>
- Khultsum, U., & Subekti, A. (2021). Penerapan Algoritma Random Forest dengan Kombinasi Ekstraksi Fitur Untuk Klasifikasi Penyakit Daun Tomat. *Jurnal Media Informatika Budidarma*, 5(1), 186. <https://doi.org/10.30865/mib.v5i1.2624>
- Lamasigi, Z. Y., -, S., -, H., & Lasena, Y. (2022). Identifikasi Tingkat Kesegaran Ikan Tuna Menggunakan Metode GLCM dan KNN. *Jambura Journal of Electrical and Electronics Engineering*, 4(1), 70–76. <https://doi.org/10.37905/jjee.v4i1.12045>
- Muhammad Haris Diponegoro, Sri Suning Kusumawardani, & Indriana Hidayah. (2021). Tinjauan Pustaka Sistematis: Implementasi Metode Deep Learning pada Prediksi Kinerja Murid. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 10(2), 131–138. <https://doi.org/10.22146/jnteti.v10i2.1417>
- Muna, N., Afriansyah, F. L., & Suprayogy, A. B. (2020). Penerapan Algoritma Random Forest Untuk Identifikasi Dehidrasi Berbasis Citra Urine. *Jurnal Informatika Polinema*, 6(3), 49–54. <https://doi.org/10.33795/jip.v6i3.348>
- Mungki Astiningrum, Arhandi, P. P., & Ariditya, N. A. (2020). Identifikasi Penyakit Pada Daun Tomat Berdasarkan Fitur Warna Dan Tekstur. *Jurnal Informatika Polinema*, 6(2), 47–50. <https://doi.org/10.33795/jip.v6i2.320>
- Muslihah, I., & Imaduddin, H. (2020). Perbandingan Algoritma Eigenface Dengan Local Binary Pattern (LBP) Pada Pengenalan Wajah. *Proceeding Seminar Nasional & Call For Papers, November 2020*, 108–115.
- Muktianto, A., & Indriyani, V. (2022). Segmentasi Tingkat Kematangan Buah Pisang Cavendish Sangat Matang Berdasarkan Warna Menggunakan Watershed. *JURIKOM (Jurnal Riset Komputer)*, 9(1), 148.

<https://doi.org/10.30865/jurikom.v9i1.3828>

- Nasution, D. A., Khotimah, H. H., & Chamidah, N. (2019). Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Computer Engineering, Science and System Journal*, 4(1), 78. <https://doi.org/10.24114/cess.v4i1.11458>
- Neneng, N., Puspaningrum, A. S., & Aldino, A. A. (2021). Perbandingan Hasil Klasifikasi Jenis Daging Menggunakan Ekstraksi Ciri Tekstur Gray Level Co-occurrence Matrices (GLCM) Dan Local Binary Pattern (LBP). *Smatika Jurnal*, 11(01), 48–52. <https://doi.org/10.32664/smatika.v11i01.572>
- Prasaja, Y. A. (2022). Perbandingan Metode Glcm Dan Lbp Dalam Klasifikasi Jenis Kayu. *Indexia*, 4(2), 61. <https://doi.org/10.30587/indexia.v4i2.4292>
- Prayoga Alwy, M Syahid Nur Wahid, Bukhari Naufal Nur Ag, & M Miftach Fakhri. (2023). Klasifikasi Penyakit Pada Padi Dengan Ekstraksi Fitur LBP dan GLCM. *Journal of Deep Learning, Computer Vision and Digital Image Processing*, 1–10. <https://doi.org/10.61255/decoding.v1i1.51>
- Putri, A. W. (2021). Implementasi Artificial Neural Network (ANN) Backpropagation Untuk Klasifikasi Jenis Penyakit Pada Daun Tanaman Tomat. *MATHunesa: Jurnal Ilmiah Matematika*, 9(2), 344–350. <https://doi.org/10.26740/mathunesa.v9n2.p344-350>
- Religia, Y., Nugroho, A., & Hadikristanto, W. (2021). Analisis Perbandingan Algoritma Optimasi pada Random Forest untuk Klasifikasi Data Bank Marketing. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 187–192.
- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 5(1), 75–82. <https://doi.org/10.31294/ijcit.v5i1.7951>
- Saidah, S., Purnamasari, R., Bainuri, A. N., & Wahid, G. S. F. (2020). Analisis Perbandingan Metode LBP dan CLBP pada Sistem Pengenalan Individu Melalui Iris Mata. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 6(3), 285. <https://doi.org/10.26418/jp.v6i3.41521>
- Sanjaya, S., Adzkiya, U., Handayani, L., & Yanto, F. (2020). Local Binary Pattern

- and Learning Vector Quantization for Classification of Principal Line of Palm-Hand. *Indonesian Journal of Artificial Intelligence and Data Mining (IJAIMD)*, 3(2), 71–77.
- Sigitta, R. C., Saputra, R. H., & Fathulloh, F. (2023). Deteksi Penyakit Tomat melalui Citra Daun menggunakan Metode Convolutional Neural Network. *Avitec*, 5(1), 43. <https://doi.org/10.28989/avitec.v5i1.1404>
- Simani, S., Lam, Y. P., Farsoni, S., & Castaldi, P. (2023). Dynamic Neural Network Architecture Design for Predicting Remaining Useful Life of Dynamic Processes. *Journal of Data Science and Intelligent Systems*, 2(3), 141–152. <https://doi.org/10.47852/bonviewjdsis3202967>
- Susanto, A. (2019). Penerapan Operasi Morfologi Matematika Citra Digital Untuk Ekstraksi Area Plat Nomor Kendaraan Bermotor. *Pseudocode*, 6(1), 49–57. <https://doi.org/10.33369/pseudocode.6.1.49-57>
- Tangkelayuk, A. (2022). The Klasifikasi Kualitas Air Menggunakan Metode KNN, Naïve Bayes, dan Decision Tree. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 9(2), 1109–1119. <https://doi.org/10.35957/jatisi.v9i2.2048>
- Umy Habibah, N., Rosyady, P. A., & Pribadi, R. P. (2023). Analisis Indeks Masa Tubuh Berbasis Citra Digital Menggunakan Metode Body Surface Area. *Jetri: Jurnal Ilmiah Teknik Elektro*, 20(2), 135–152. <https://doi.org/10.25105/jetri.v20i2.15398>
- Wijaya, N., & Ridwan, A. (2019). Klasifikasi Jenis Buah Apel Dengan Metode K-Nearest Neighbors Dengan Ekstraksi Fitur Hsv Dan Lbp. *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, 8(1), 74–78. <https://doi.org/10.32736/sisfokom.v8i1.610>
- Zyra, S. N., Alamsyah, T. P., & Yuliana, R. (2022). Penggunaan E-Learning Berbasis Edmodo Terhadap Hasil Belajar Kelas 4 Sekolah Dasar. *Jurnal PGSD: Jurnal Ilmiah Pendidikan Guru Sekolah Dasar*, 15(2), 97–106. <https://doi.org/10.33369/pgsd.15.2.97-106>