



## Klasifikasi Penyakit Pada Padi Dengan Ekstraksi Fitur LBP dan GLCM

<sup>1</sup>Ananta Dwi Prayoga Alwy, <sup>2\*</sup>M. Syahid Nur Wahid, <sup>3</sup>Bukhari Naufal Nur Ag, <sup>4</sup>M. Miftach Fakhri

<sup>1,3</sup>Prodi Teknik Komputer, Universitas Negeri Makassar

<sup>2,4</sup>Prodi Pendidikan Teknik Informatika dan Komputer, Universitas Negeri Makassar

Email: ananta.alwy01@gmail.com<sup>1</sup>, syahid@unm.ac.id<sup>2</sup>, bukhari.asrullah@gmail.com<sup>3</sup>, fakhri@unm.ac.id<sup>4</sup>

### ABSTRAK

Padi adalah salah satu bahan pangan yang menjadi sumber utama bagi masyarakat Indonesia. Padi bukan hanya sebagai sumber bahan makanan namun juga menjadi ladang untuk mencari nafkah bagi kaum petani. Namun sering kali kita menemui kasus dimana sering terjadinya gagal panen dikarenakan wabah atau penyakit, baik itu diakibatkan oleh hama ataupun kondisi iklim yang tidak mendukung. Penyakit pada padi sendiri ada cukup banyak dan masing-masing dari penyakit tersebut memiliki penanggulangan atau pencegahan yang berbeda pula. Maka dari itu dibuatlah sebuah sistem yang dapat mengklasifikasikan jenis penyakit yang terdapat pada tanaman padi. Penelitian ini mengusulkan Klasifikasi Penyakit Pada Padi dengan Ekstraksi Fitur LBP dan GLCM. Dalam penelitian ini digunakan 120 dataset citra daun padi. Proses dan metode yang diusulkan yaitu Akuisisi citra, preprocessing, segmentasi dengan metode konversi nilai menjadi biner, operasi morfologi dengan menggunakan Area Open, ekstraksi fitur menggunakan LBP dan GLCM, dan terakhir tahap klasifikasi dengan Decision Tree. Berdasarkan hasil pengujian, diperoleh tingkat akurasi sebesar 90%. Diharapkan dengan adanya sistem yang dibuat ini dapat membantu sebagian besar para petani untuk mencegah terjadinya penyakit yang terjangkit pada padi, sehingga hasil panen diharapkan dapat lebih meningkat dengan kualitas yang baik.

**Kata Kunci:** Citra, LBP, GLCM, Decision Tree, Penyakit Padi

### ABSTRACT

*Rice is one of the foodstuffs that is the main source for the Indonesian people. Rice is not only a source of food but also a field to make a living for the farmers. However, we often encounter cases where frequent crop failures occur due to outbreaks or diseases, be it caused by pests or unfavorable climatic conditions. There are quite a lot of diseases in rice and each of these diseases has a different countermeasure or prevention. Therefore, a system was created that can classify the types of diseases found in rice plants. This study proposes a Classification of Diseases in Rice with LBP and GLCM Feature Extraction. In this study, 120 rice leaf image datasets were used. The proposed processes and methods are image acquisition, preprocessing, segmentation with the method of converting values into binary, morphological operations using Area Open, feature extraction using LBP and GLCM, and finally the classification stage with Decision Tree. Based on the test results, an accuracy rate of 90% was obtained. It is hoped that the existence of this system can help most farmers to prevent diseases infected with rice, so that crop yields are expected to increase with good quality.*

**Keywords:** Citra, LBP, GLCM, Decision Tree, Rice Disease

## 1. PENDAHULUAN

Pengolahan pangan di Indonesia setiap tahunnya terus meningkat, yang berakibat kebutuhan tanaman padi juga turut ikut meningkat. Pada lingkup topik ini menyangkut penyakit pada tanaman yang dapat mengubah kehidupan umat manusia dari cukup pangan menjadi kelaparan dan bahkan kematian. Pada tahun 1940-an sekitar dua juta penduduk Bangladesh mati kelaparan dikarenakan tanaman padi yang terjangkit jamur *Helminthosporium oryzae*. Di Indonesia, penyakit tanaman padi ialah hawar daun bakteri (*Xanthomonas campestris* pv. *oryzae*), penyakit tungro (virus tungro), bercak daun *Pyricularia* (*Pyricularia grisea*), busuk batang (*Helminthosporium sigmoideum*), hawar pelepah daun, kerdil hampa (Reget stunt) dan kerdil rumput (Grassy stunt). Kehilangan hasil padi akibat gangguan hawar daun bakteri berkisar antara 15–24%. Perkembangan penyakit tungro di Surakarta, Jawa Tengah, pada 1994/1995 menyebabkan 12.340 hektar tanaman padi puso dengan nilai kerugian sekitar Rp 25 milyar. Pada tahun 2010, penyakit kerdil hampa dan kerdil rumput mewabah dan menyebabkan gagal panen di beberapa sentra penghasil padi di Pulau Jawa. Pada periode 1997–2001, penyakit blas merusak 13.499 hektar tanaman padi sawah, 402 hektar di antaranya puso. Penyakit hawar pelepah berkembang di sentra produksi padi yang intensif [1].

Penyakit pada tanaman padi bisa dilihat dari adanya perubahan pada daun, akar, batang dan lain-lain. Namun, terkadang akan menjadi masalah ketika petani tidak berada di sawah tersebut sehingga tanaman padi yang

terjangkit penyakit tidak dapat dicegah. Untuk mengetahui daun yang terjangkit oleh penyakit, dapat dibedakan berdasarkan perubahan morfologi yang terjadi pada daunnya [2].


Analisis tentang identifikasi penyakit pada tanaman dengan menyajikan sebuah metode berdasarkan warna, deteksi tepi dan histogram yang cocok. Pada penelitian ini dibagi menjadi dua tahap adalah utama. Pada tahap pertama semua daun sehat dan penyakit diberikan masukan ke Matlab. Kemudian komponen warna Red Green Blue (RGB) dipisahkan kedalam gambar skala abu-abu dan menerapkan Metode tepi yaitu metode Canny. Setelah itu histogram adalah plot untuk setiap komponen gambar daun yang sehat dan penyakit. Pada tahap kedua proses yang sama diulang untuk pengujian daun dan dibandingkan semua hasil disimpan dan mengidentifikasi hasil. Pada sistem ini dilakukan ekstraksi ciri terhadap perubahan morfologi pada daun tanaman padi yang terkena penyakit sesuai dengan tekstur. Secara umum, klasifikasi penyakit pada daun tanaman padi ini terdiri dari 5 bagian utama, yaitu: preprocessing, color extraction, segmentation, feature extraction dan classification. Proses klasifikasi penyakit ini terdiri dari berapa proses, yaitu proses ekstraksi warna menggunakan metode grayscale, dan histogram, kemudian segmentation menggunakan deteksi tepi dan ekstraksi tekstur menggunakan LBP (Local binary pattern).

Terdapat juga penelitian yang menggunakan metode K-Nearest Neighbor sebagai klasifikasinya dan Local binary pattern untuk ekstraksi fiturnya seperti pada penelitian yang berjudul Ekstraksi Citra Menggunakan Metode LBP dan KNN untuk Identifikasi Jenis Anggrek. Dalam penelitian ini sistem dapat mendeteksi jenis anggrek dengan akurasi 77% [3]. Kemudian, ada juga penelitian yang menggunakan Decision Tree untuk mengklasifikasi Produksi Laris menggunakan algoritma C4.5 yang dimana algoritma ini akan mengkonstruksi pohon keputusan dari data pelatihan, yang berupa kasus-kasus atau record-record dalam basis data. Penelitian ini menggunakan metode klasifikasi KNN dengan tingkat akurasi 87% [4]. Lalu terdapat penelitian yang membahas identifikasi penyakit pada tanaman padi dengan menggunakan kombinasi ciri bentuk dan ciri tekstur yang digunakan untuk mengoptimasikan akurasi. Untuk mendapatkan karakteristik bentuk proses segmentasi menggunakan Otsu dan morfologi. Hasil yang diperoleh dari 30 data uji adalah 93% [5].

Dari beberapa penelitian diatas, nilai akurasi klasifikasi semakin tidak akurat karena metode dan prosedur yang tidak tepat. Dengan menggunakan metode dan teknik yang tepat untuk kembali mendeteksi penyakit pada padi dapat membantu para petani untuk mengenali dan mencegah terjangkitnya penyakit pada tumbuhan lahan padi mereka dengan lebih akurat. Pada penelitian ini, kami mengusulkan Klasifikasi Penyakit Pada Padi Dengan Ekstraksi Fitur LBP dan Warna. Klasifikasi penyakit ini terdiri dari 3 jenis yaitu Brown Spot, Hispa dan Leaf Blast. Metode yang diusulkan ada 6 tahap yaitu, akuisisi citra, segmentasi citra, operasi morfologi, ekstraksi fitur menggunakan LBP, ekstraksi ciri dengan menggunakan GLCM dan klasifikasi dengan Decision Tree.

## 2. METODE PENELITIAN

Penelitian ini memiliki metode yang terdiri dari 4 tahapan utama dalam akuisisi citra: preprocessing, segmentasi, ekstraksi fitur, dan klasifikasi. Pada fase preprocessing diterapkan operasi transformasi atau dari nilai citra warna menjadi biner, tahapan segmentasi melakukan konversi dari nilai blue yang ada pada citra menjadi nilai biner, operasi morfologi cukup dengan menggunakan metode area open kemudian untuk klasifikasinya menggunakan *Decision Tree*.



Gambar 1. Bagan Tahap Klasifikasi

## 2.1 Akuisisi Citra

Pada tahapan pengumpulan data dilakukan metode akuisisi citra dengan mencari sumber di kaggle.com. Dataset yang digunakan lebih spesifik pada penyakit padi. Hasil pencarian yang ditemukan, kami mendapatkan dataset yang memiliki 3 atribut yaitu *Brown Spot*, *Hispa* dan *Leaf Blast*. Citra yang diambil berupa daun padi atau daun padi yang telah terjangkit penyakit, pengambilan citra menggunakan kamera dengan *background* layar putih seperti pada gambar 2.



Gambar 2. Daun Padi

## 2.2 Segmentasi Citra


Pada proses segmentasi dilakukan dengan ekstraksi ciri warna untuk mengambil nilai pada ruang warna blue. Setelah itu dilakukan binerisasi pada ekstraksi warna yang telah didapat untuk selanjutnya akan dilakukan *invers*. Pada proses *invert image* dilakukan proses untuk mengubah warna piksel putih menjadi warna piksel hitam, hal ini bertujuan untuk mengubah *background* berwarna putih dari citra yang dimiliki menjadi warna hitam [6]. Adapun beberapa metode yang digunakan dalam melakukan segmentasi sebagai berikut.

### a. Metode Otsu *thresholding*

Metode otsu merupakan salah satu metode segmentasi yang menggunakan nilai ambang secara otomatis dengan cara mengubah citra digital warna abu-abu menjadi hitam putih berdasarkan perbandingan nilai ambang dengan nilai warna piksel citra digital [6]. *Thresholding* adalah teknik segmentasi citra yang memisahkan objek dari latar belakang suatu citra berdasarkan perbedaan gelap-terangnya. Area citra yang cenderung gelap dibuat lebih gelap (hitam sempurna dengan nilai intensitas 0), dan area citra yang cenderung lebih terang dibuat lebih terang (putih ideal dengan nilai intensitas 1). Oleh karena itu, hasil dari proses segmentasi *thresholding* adalah citra biner dengan nilai intensitas piksel 0 atau 1. Setelah citra tersegmentasi atau objek telah berhasil dipisahkan dari latar belakang, citra biner yang dihasilkan dapat digunakan. Gunakan sebagai mask untuk proses cropping agar citra aslinya keluar tanpa background atau dengan background yang bisa diubah-ubah [7].

$$P_i = \frac{n_i}{N} \quad (1)$$

Nilai ambang yang akan dicari dari suatu citra grayscale dinyatakan dengan  $k$ . Nilai  $k$  berkisar antara 0 sampai dengan  $L-1$ , dengan nilai  $L=256$  (simbol histogram adalah  $P_i$ ). Jadi probabilitas setiap piksel pada level ke  $i$  dinyatakan dengan persamaan 1. Untuk setiap probabilitas piksel ke- $i$  ( $P_i$ ) adalah sama dengan jumlah piksel dengan tingkat kebutuhan  $i$  ( $n_i$ ) dibagi dengan total jumlah piksel pada citra ( $N$ ).



Gambar 3. Hasil Segmentasi

## 2.3 Operasi Morfologi


Hasil segmentasi yang telah dilakukan masih belum sempurna, terdapat beberapa ruang citra biner yang masih harus dilakukan perbaikan, kesalahan ini nantinya dapat berdampak pada hasil klasifikasi citra. Untuk mengurangi kemungkinan tersebut, dilakukan penghilangan darau menggunakan operasi morfologi *Erosi* dan *Area Open* yang akan digunakan dalam operasi morfologi penelitian ini.

a. *Erosi*

Erosi adalah salah satu dari dua bentuk dasar pencitraan selain pelebaran(dilasi). Operasi erosi, seperti pelebaran, dilakukan dalam biner. Erosi akan menyebabkan objek pada citra menipis atau terkikis [7]. Jika X dan B himpunan dalam Z, erosi X oleh B dinyatakan dengan  $X \ominus B$ , didefinisikan sebagai :

$$X \ominus B = \{z \mid (B_z) \subseteq X\} \quad (2)$$

Pada persamaan (1) menunjukkan bahwa erosi X oleh B adalah kumpulan semua titik dimana B ditranslasikan oleh Z di dalam isi X



Gambar 4. Operasi Erosi

b. *Area Open*

*Area Open* adalah kombinasi proses dimana citra digital mengembang mengikuti operasi erosi. Proses pembukaan citra memiliki efek menghaluskan batas-batas objek, memisahkan objek yang digabungkan sebelumnya, dan menghilangkan objek yang kecil dari ukuran terstruktur. Operasi *Area Open* dinyatakan dalam bentuk persamaan.

$$X \circ B = (X \ominus B) \oplus B \quad (3)$$

Dari persamaan (3) menunjukkan, operasi opening pada set X mengalami erosi lebih dulu, kemudian dilanjutkan dengan operasi dilasi. Bisa terlihat pada gambar 10, opening akan menghilangkan objek kecil seperti pada

## 2.4 Estraksi Ciri

Citra yang telah melalui proses segmentasi dan morfologi akan diekstrak fitur warna objek pada citranya. Warna objek yang akan diekstrak adalah komponen warna *Red*, *Green*, *Blue*. Adapun persamaan yang digunakan sebagai berikut :

$$Z = \frac{\sum x}{\sum y} \quad (4)$$

Rumus untuk mendapatkan nilai warna dapat dilihat pada persamaan (4) dimana Z diperoleh dari hasil pembagian jumlah nilai chanel warna (*Red/Green/Blue*) pada citra asli X dan jumlah nilai chanel warna (*Red/Green/Blue*) objek pada gambar telah di segmentasi.

## 2.5 Klasifikasi Decision Tree

*Decision tree* adalah algoritma yang digunakan dalam proses klasifikasi maupun prediksi dengan menggunakan metode pembentukan pohon keputusan. Pada penerapannya, pohon keputusan biasa digunakan untuk melakukan penalaran agar mendapatkan jawaban dari masalah di dapat [4]. Peranan pohon keputusan sebagai alat bantu pengambilan keputusan (*decision support tool*) telah dikembangkan oleh manusia untuk membantu mencari dan membuat keputusan masalah dengan memperhitungkan berbagai macam faktor yang ada di dalam lingkup masalah tersebut. Dengan pohon keputusan, manusia dapat dengan mudah mengidentifikasi dan melihat hubungan antara faktor-faktor yang mempengaruhi suatu masalah dan dapat mencari penyelesaian terbaik dengan memperhitungkan faktor-faktor tersebut [8]. Pada metode penelitian untuk klasifikasi ini menggunakan 2 persamaan yaitu *Entropy* dan *Giant*.

a. *Entropy*

Entropy didefinisikan sebagai suatu parameter untuk mengukur heteroginitas dalam suatu himpunan data, semakin heterogen sebuah data maka semakin besar nilai entropynya, rumus entropy sebagai berikut.

$$Entropy(S) = \sum_{i=1}^n - p_i \log_2 p_i \quad (5)$$

Dari persamaan (5) menunjukkan dimana S adalah himpunan kasus yang dimana n adalah jumlah partisi dari S. berikutnya untuk porsi atau rasio antara jumlah sampel kelas di kelas i dengan jumlah pada himpunan data ( $P_i$ ). Entropy maksimum sama dengan 1 diperoleh dari dua kelas memiliki himpunan data yang sama maka dikatakan maksimum, sedangkan apabila himpunan data memiliki dua kelas dengan jumlah sampel yang pada salah satu kelas adalah 0 akan memiliki nilai entropy minimum sama dengan 0.

b. *Information Gain*


Information Gain merupakan teknik seleksi fitur yang memakai metode scoring untuk nominal ataupun pembobotan atribut kontinu yang didiskretkan menggunakan maksimal entropy. Suatu entropy digunakan untuk mendefinisikan nilai Information Gain. Entropy menggambarkan banyaknya informasi yang dibutuhkan untuk mengkodekan suatu kelas [6]. Information Gain (IG) dari suatu term diukur dengan menghitung jumlah bit informasi yang diambil dari prediksi kategori dengan ada atau tidaknya term dalam suatu dokumen.

$$InfoGain(S, A) = Entropy(S) - \sum_{v \in Value(A)} \frac{|S_v|}{S} Entropy(S_v) \quad (6)$$

Dari persamaan (6) menunjukkan Dimana S adalah jumlah seluruh fitur, A adalah kategori, Sv adalah jumlah sampel untuk nilai v, v adalah nilai yang mungkin untuk kategori A, Si adalah fitur ke i dan Value(A) adalah himpunan nilai-nilai yang mungkin untuk kategori A.

## 2.6 Ekstraksi Fitur 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 invariant terhadap pencahayaan yang berbeda [9]. *Local binary pattern* (LBP) merupakan suatu metode yang menggunakan deskriptor tekstur yang dapat juga digunakan untuk pengenalan wajah, karena gambar wajah dapat dilihat sebagai sebuah komposisi *micro-texture-pattern* yaitu suatu operator non parametrik yang menggambarkan tata ruang lokal citra. Dengan menggunakan metode LBP akan merubah piksel dari gambar menjadi angka desimal, yang disebut dengan istilah LBP atau kode LBP yang akan mengkodekan struktur lokal pada sekitar setiap piksel gambar. Seperti ilustrasi pada gambar 5.



**Gambar 5.** Ekstraksi Fitur LBP

Setiap pixel dibandingkan dengan 8 nilai piksel disekelilingnya dengan mengurangi nilai pixel dengan pusat 3x3, nilai-nilai negatif yang dihasilkan kemudian akan dikodekan dengan nilai 0, dan nilai-positif positif yang dihasilkan akan dikodekan dengan nilai 1. Setelah itu, menyusun 8 nilai biner yang menggunakan arah searah jarum jam atau sebaliknya dan merubah 8 bit biner kedalam nilai desimal untuk menggantikan nilai piksel pada pusat citra, yang dimulai dari salah bagian atas kiri.

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(i_p - i_c) 2^p \quad (7)$$

Dari persamaan (7) menunjukkan dimana  $i_p$  dan  $i_c$  merupakan masing-masing nilai, nilai-nilai gray-level dari pusat pixel dan P sekitarnya piksel di lingkungan lingkaran dengan R radius, dan fungsi  $s(x)$  didefinisikan sebagai:

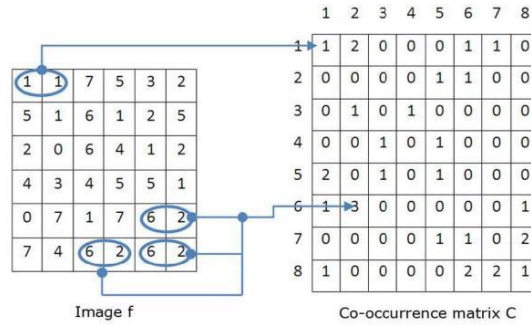
$$s(x) = \begin{cases} 1, & \text{if } x \geq 0 \\ 0, & \text{if } x < 0 \end{cases} \quad (8)$$

Dari definisi tersebut, operator LBP adalah invarian untuk transformasi skala abu-abu monoton, yang akan melestarikan nilai piksel agar intensitas dalam lingkungan lokal. Histogram label LBP dihitung atas suatu daerah dapat dimanfaatkan sebagai descriptor tekstur. Operator LBP(P,R) menghasilkan 2P nilai output yang berbeda, sesuai dengan nilai 2P pola biner yang berbeda yang dibentuk oleh P piksel pada lingkungan. Jika gambar diputar, ekitarnya piksel di setiap lingkungan akan bergerak sepanjang perimeter lingkaran, sehingga akan mengakibatkan LBP akan memberikan nilai berbeda, kecuali untuk pola dengan hanya 1 dan 0. Untuk menghapus efek rotasi, sebuah LBP rotasi-invarian.

## 2.7 Ekstraksi Fitur GLCM

Proses ekstraksi fitur dengan menggunakan GLCM dilakukan setelah proses segmentasi. Gambar 6. menunjukkan contoh citra daun padi yang sudah melalui proses segmentasi. Setelah dilakukan proses segmentasi, data citra hasil segmentasi digunakan sebagai input data proses ekstraksi fitur.





**Gambar 6.** Matriks Kookurensi

Metode GLCM atau analisis pada tekstur merupakan suatu metode untuk melakukan klasifikasi pada suatu citra, GLCM pada dasarnya merupakan matrix persegi yang memiliki sifat-sifat tertentu dengan distribusi spesial. GLCM menggunakan perhitungan orde kedua. Pada orde pertama, pengukuran tekstur menggunakan perhitungan statistik didasarkan pada nilai piksel citra asli semata, seperti varians, dan tidak memperhatikan orde kedua [10]. Untuk mendapatkan nilai piksel kookurensi dapat dilihat pada persamaan 9 dimana  $d$  adalah jarak antara 2 piksel yaitu  $(x_1, y_1)$  dan  $(x_2, y_2)$

$$P = \sum_{x=1}^K \sum_{y=1}^K \begin{cases} 1, \text{if } I(x, y) = i \text{ and } I(x + d_x, y + d_y) = i \\ 0, \text{lainnya} \end{cases} \quad (9)$$

Dari persamaan diatas dapat dihasilkan matriks kookurensi dari jarak orientasi sudut, matriks yang didapat kemudian ditambahkan dengan matriks transposenya untuk mejadikan simetris terhadap sumbu diagonal. Setelah diperoleh matriks kookurensi, selanjutnya untuk mendapatkan persamaan untuk mencari nilai tekstur dapat didefinisikan sebagai berikut.

a. *Energy (Angular Second Moment/Energy)*

Mengukur keseragaman tekstur, energi akan bernilai tinggi ketika nilai pixel mirip satu sama lain sebaliknya akan bernilai kecil menandakan nilai dari GLCM normalisasi adalah heterogen. Nilai maksimum energi adalah 1 artinya distribusi pixel dalam kondisi konstan atau bentuknya yang berperiodik (tidak acak).

$$\sum_{i=1}^K \sum_{j=1}^K p i^2 j \quad (10)$$

Pada persamaan (10) dapat dilihat dimana (i) adalah baris, (j) adalah kolom dan  $\sum$  adalah jumlah.  $p(i, j)$  menyatakan nilai yang dimiliki pada baris (i) dan kolom (j) pada matriks kookurensi. Semakin homogen suatu citra, maka nilai energi-nya juga akan semakin besar.

b. *Contrast*

Frekuensi spasial dari citra dan perbedaan moment GLCM yang dihasilkan. Perbedaan yang dimaksud adalah perbedaan tinggi dan rendahnya suatu pixel. Kontras bernilai 0 jika nilai ketetanggaan pixel sama.

$$\sum_{i=1}^K \sum_{j=1}^K (i - j)^2 p i j \quad (11)$$

Pada persamaan (10) dapat dilihat dimana (i) adalah baris, (j) adalah kolom dan  $\sum$  adalah jumlah.  $p(i, j)$  menyatakan nilai yang dimiliki pada baris (i) dan kolom (j) pada matriks kookurensi. Semakin homogen suatu citra, maka nilai energi-nya juga akan semakin besar. Jika terdapat perbedaan tinggi dan rendah dari sebuah piksel maka kontras akan dikurangi dari baris dan kolom.

c. *Homogeneity*

Homogeniti disebut juga dengan Inverse Difference Moment. Homogeniti digunakan untuk mengukur tingkat homogenitas citra. Nilai ini digunakan dikarenakan sangat sensitif terhadap nilai disekitar diagonal utama. Jika nilai yang dihasilkan oleh pixel sama atau seragam maka akan bernilai tinggi. Kebalikan dari Contrast, bernilai besar jika pada saat energi bernilai tetap mempunyai nilai pixel yang sama.

$$\sum_{i=1}^K \sum_{j=1}^K \frac{p i j}{1 + |i - j|} \quad (12)$$

d. *Correlation*

Korelasi menyatakan ukuran ketergantungan linear derajat keabuan citra sehingga dapat memberikan petunjuk adanya struktur linear dalam citra. Untuk mendapatkan nilai korelasi dapat dilihat pada persamaan (13).

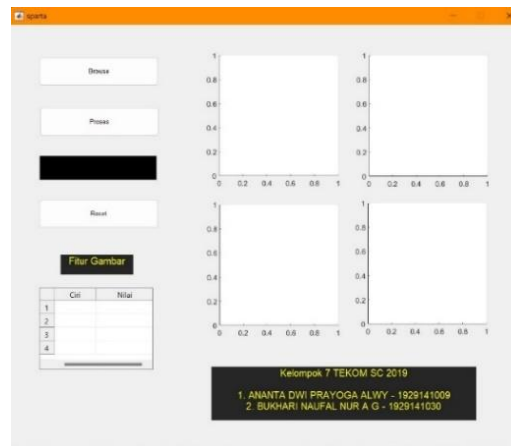
$$\sum_{i=1}^K \sum_{j=1}^K \frac{(i-m_r)(j-m_c)p_{ij}}{\sigma_r \sigma_c} \quad (13)$$

Dimana  $\sigma_r \neq 0$ ;  $\sigma_c \neq 0$   $P(i,j)$  adalah baris elemen ke- $i$ , kolom ke- $j$  dari matriks kookurensi yang sudah dinormalisasi.  $m_r$  = nilai rata-rata baris yang dinormalisasi.  $m_c$  = nilai rata-rata kolom.  $\sigma_r$  dan  $\sigma_c$  = standar deviasi dihitung berdasarkan baris dan kolom secara berurutan

### 3. HASIL DAN PEMBAHASAN

Pada penelitian ini terdapat 2 dataset yang terdiri dari data latih dan data uji. Data latih terdiri dari 90 citra yang terdiri dari 30 citra penyakit *Brown Spot*, 30 citra penyakit *Hispa* dan 30 citra *Leaf Blast*. Kemudian data uji memiliki 30 citra dengan masing-masing 12 dari penyakit *Brown Spot*, *Hispa* dan *Leaf Blast*.

Pada Gambar 7 ditampilkan GUI dari Klasifikasi Penyakit Pada Padi dengan menampilkan hasil dan tahap sebelum menentukan jenis penyakit. Pada bagian ruang pertama nantinya akan menampilkan data citra asli, lalu ruang kedua menampilkan hasil dari segmentasi, pada ruang ketiga nantinya akan menampilkan hasil operasi morfologi dengan menggunakan metode *area-open*, lalu yang terakhir akan menampilkan hasil ekstraksi ciri yang telah digunakan.



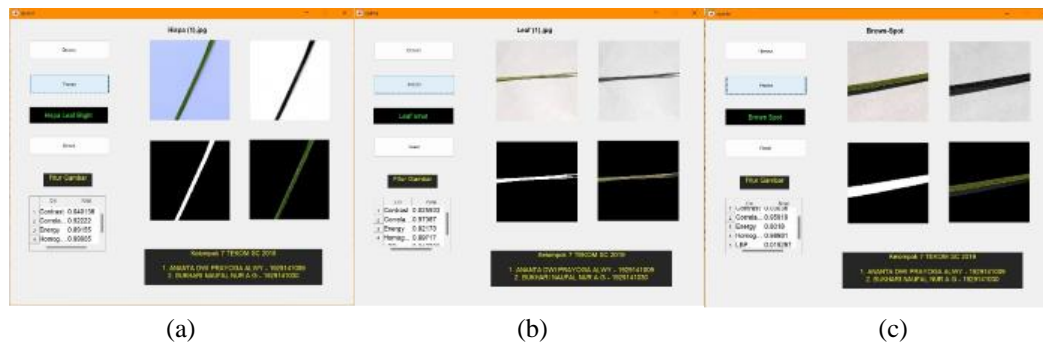
**Gambar 7.** Tampilan GUI Klasifikasi Penyakit Pada Padi

Proses untuk melakukan klasifikasi pada melalui GUI ini dapat dilihat pada Gambar 8. Langkah yang pertama dilakukan adalah dengan mencari data citra yang akan dilakukan uji coba dengan menekan tombol “Browse” kemudian dilakukan proses mulai dari segmentasi hingga ekstraksi fitur dengan menekan tombol “Proses”. Lalu pada bagian kolom akhir terdapat status dari ekstraksi fitur GLCM yang dimana nantinya akan ditampilkan 4 fitur yaitu *contrast*, *correlation*, *energy* dan *homogeneity*.



**Gambar 8.** Proses Melakukan Klasifikasi

Pada proses untuk menentukan penyakit pada padi, dilakukan beberapa tahapan untuk mendapatkan hasil yang sesuai. Citra asli atau data data citra uji coba yang telah di input akan melalui proses segmentasi terlebih dahulu, proses segmentasi ini bertujuan untuk mengkonversi nilai citra pada ruang *Blue* menjadi nilai Biner. Selanjutnya dilakukan operasi morfologi untuk menghilangkan menyesuaikan bentuk dari tepi matrix yang tidak sesuai. Terakhir melakukan ekstraksi fitur dengan menggunakan *contrast*, *correlation*, *energy* dan *homogeneity*. Nilai yang telah didapat nantinya akan diklasifikasikan berdasarkan hasil ekstraksi fitur yang diperoleh dengan menggunakan *Decision Tree*. Nantinya hasil klasifikasi atau penentuan penyakit pada padi ditampilkan dalam bentuk text atau status yang berada tepat dibawa tombol “Proses”.



**Gambar 9.** Citra hispa (a), Citra *leaf* (b), Citra *brown-spot* (c)

**Tabel 1.** Hasil Uji Dataset Penyakit Pada Padi

No.	Kelas	contrast	correlation	Energy	Homogeneity	Local Binary Pattern	Hasil uji
1	Brown Spot	0.022721525	0.982201514	0.728164306	0.994445397	0.02006715	Brown Spot
2	Brown Spot	0.019612371	0.987423711	0.850832843	0.996446429	0.018319579	Brown Spot
3	Brown Spot	0.019612371	0.987423711	0.850832843	0.996446429	0.018319579	Brown Spot
4	Brown Spot	0.030360255	0.959190867	0.80179521	0.98980914	0.019297482	Brown Spot
5	Brown Spot	0.018094719	0.986818551	0.67845015	0.99655882	0.019856356	Brown Spot
6	Brown Spot	0.049225985	0.987291229	0.670724444	0.987193451	0.021057129	Brown Spot
7	Brown Spot	0.049001702	0.986034966	0.671038039	0.986172958	0.021003392	Brown Spot
8	Brown Spot	0.032405689	0.968595011	0.793090224	0.988749109	0.019300535	Brown Spot
9	Brown Spot	0.02816267	0.955457995	0.964844815	0.998265497	0.017275719	Leaf smut
10	Brown Spot	0.018618667	0.987237821	0.848875474	0.996823637	0.018358393	Brown Spot
11	Hispa Leaf Blight	0.040135575	0.922219744	0.891545854	0.990052385	0.01803234	Hispa Leaf Blight
12	Hispa Leaf Blight	0.038440109	0.965088369	0.871879869	0.990044805	0.018255748	Hispa Leaf Blight
13	Hispa Leaf Blight	0.028475845	0.967922525	0.883566978	0.994728096	0.018093245	Hispa Leaf Blight
14	Hispa Leaf Blight	0.034346486	0.967551401	0.855328428	0.99202889	0.018432841	Hispa Leaf Blight
15	Hispa Leaf Blight	0.011586432	0.960843219	0.914637342	0.996250855	0.017869286	Leaf smut
16	Hispa Leaf Blight	0.027330785	0.959404646	0.889046483	0.993251897	0.017997736	Hispa Leaf Blight
17	Hispa Leaf Blight	0.040135575	0.922219744	0.891545854	0.990052385	0.01803234	Hispa Leaf Blight
18	Hispa Leaf Blight	0.038440109	0.965088369	0.871879869	0.990044805	0.018255748	Hispa Leaf Blight





19	Hispa Leaf Blight	0.027330785	0.959404646	0.889046483	0.993251897	0.017997736	Hispa Leaf Blight
20	Hispa Leaf Blight	0.03219374	0.97270134	0.87603706	0.994289897	0.018226806	Hispa Leaf Blight
21	Leaf smut	0.025933481	0.973665325	0.921728246	0.99716622	0.017733203	Leaf smut
22	Leaf smut	0.021630802	0.98317701	0.882082093	0.995645444	0.017974792	Leaf smut
23	Leaf smut	0.03037027	0.986573301	0.743291944	0.991690815	0.019908292	Leaf smut
24	Leaf smut	0.02644145	0.974158076	0.928930151	0.996214043	0.017673165	Leaf smut
25	Leaf smut	0.031627954	0.98689876	0.636964958	0.990121872	0.021314157	Leaf smut
26	Leaf smut	0.026117172	0.990215045	0.84066349	0.995610286	0.018299645	Brown Spot
27	Leaf smut	0.021066761	0.981416731	0.906723339	0.996778884	0.01771228	Leaf smut
28	Leaf smut	0.021110795	0.984671698	0.886339118	0.996764672	0.018054904	Leaf smut
29	Leaf smut	0.032348149	0.989642911	0.845311654	0.995525387	0.018258406	Leaf smut
30	Leaf smut	0.02820121	0.989508996	0.744573275	0.994486615	0.019451046	Leaf smut

Pada tabel 1 menunjukkan masih terdapat akurasi yang kurang tepat pada saat melakukan klasifikasi. Dari hasil analisa didapatkan bahwa setiap nilai ambang citra memiliki parameter masing-masing, apabila ada satu parameter yang nilainya hampir sama, maka sistem akan secara otomatis memasukkannya dalam kelas lain.

Berdasarkan hasil klasifikasi Penyakit pada Padi yang ditunjukkan pada Tabel 1, dapat dihitung tingkat akurasinya dengan menggunakan rumus. Dimana  $a$  adalah akurasi,  $x$  adalah hasil dari penyakit yang sesuai dan  $z$  adalah jumlah data citra keseluruhan.

$$A = \frac{x}{z} \times 100$$

**Tabel 2.** Hasil Klasifikasi Data Uji

Klasifikasi	Hasil Klasifikasi Jumlah			Akurasi (A)
	Citra	Sesuai (x)	Error (z)	
<i>Brown-Spot</i>	10	9	1	90%
<i>Hispa</i>	10	9	1	
<i>Leaf</i>	10	9	1	
Total	30	27	3	

Dari Tabel 2 di atas dapat dilihat bahwa terdapat 1 citra pada data uji yang tidak sesuai dengan data aslinya. Citra tersebut adalah data citra penyakit *Leaf* yang dimana pada saat melakukan klasifikasi, citra tersebut terdeteksi sebagai penyakit *Brown-Spot*, hal ini dikarenakan karakter atau pola corak pada penyakit *Leaf* hampir sama dengan *Brown-Spot* yaitu memiliki bercak coklat pada area daun padi. Sehingga pada saat proses klasifikasi data citra tersebut dimasukkan kedalam kelompok Penyakit *Leaf*.

#### 4. KESIMPULAN DAN SARAN

Berdasarkan penelitian dengan judul Klasifikasi Penyakit Pada Padi Dengan Ekstraksi Fitur LBP dan GLCM, dapat ditarik beberapa kesimpulan, sebagai berikut:

- 1) Dalam melakukan proses klasifikasi GLCM memanfaatkan 4 fitur ciri yaitu *Energy*, *Contrast*, *Homogenity*, *Corelation* yang dimana 4 fitur ciri ini dapat mengubah atau mengembalikan nilai sebuah pixel berdasarkan nilai dari hasil segmentasi yang di peroleh.



- 2) Dalam Penelitian ini kami menggunakan *Decision Tree* sebagai Klasifikasi Penyakit Pada padi. Dengan membagi setiap record-record 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.

## REFERENSI

- [1] Bambang Nuryanto, "PENGENDALIAN PENYAKIT TANAMAN PADI BERWAWASAN LINGKUNGAN MELALUI PENGELOLAAN KOMPONEN EPIDEMIK," Pengendalian penyakit t, vol. 37 No.1, p. 8, Jun. 2018.
- [2] Jani Kusanti, "Klasifikasi Penyakit Daun Padi Berdasarkan Hasil Ekstraksi Fitur GLCM Interval 4 Sudut," Jurnal Informatika: Jurnal Pengembangan IT (JPIT, vol. 03, No.01, p. 6, Jan. 2018.
- [3] Danar Putra Pamungkas, "Ekstraksi Citra menggunakan Metode GLCM dan KNN untuk Identifikasi Jenis Anggrek (Orchidaceae)," Innovation in Research of Informatics (INNOVATICS), vol. 1 NO. 2, p. 6, 2019.
- [4] Annida Purnamawati, "Deteksi Penyakit Daun pada Tanaman Padi Menggunakan Algoritma Decision Tree, Random Forest, Naïve Bayes, SVM dan KNN," InfoTekJar : Jurnal Nasional Informatika dan Teknologi Jaringan, vol. 5, no. 1, p. 4, 2020.
- [5] "Kombinasi Ciri Bentuk dan Ciri Tekstur Untuk Identifikasi Penyakit Pada Tanaman Padi," Jurnal Teknik Informatika dan Sistem Informasi, vol. 7, No. 2, p. 14, Agustus 2020.
- [6] Slamet Imam Syafi'i, "SEGMENTASI OBYEK PADA CITRA DIGITAL MENGGUNAKAN METODE OTSU THRESHOLDING," Jurnal Informatika, vol. 13, No. 1, p. 8, Mei 2015, doi: 10.9744/informatika.13.1.1-8.
- [7] Bukhari Naufal, "Klasifikasi Kematangan Daun Selada Berdasarkan Fitur Warna Menggunakan K-Nearest Neighbors," Techno Xplore, vol. 7 No: 1, p. 10, Apr. 2022.
- [8] Fajri Profesio Putra, "Analisis Kinerja Decision Tree C4.5 dalam Prediksi Potensi Pelunasan Kredit Calon Debitur," JURNAL INOVTEK POLBENG - SERI INFORMATIKA, vol. 2, NO. 2, p. 9, Nov. 2017.
- [9] Dwi Retnoningrum, "Ekstraksi Ciri Pada Telapak Tangan Dengan Metode Local Binary Pattern (LBP)," Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, vol. 3, No. 3, no. 1, p. 8, Mar. 2019.
- [10] Maghfirah Ramadhani, "KLASIFIKASI JENIS JERAWAT BERDASARKAN TEKSTURDENGANMENGGUNAKAN METODE GLCM," e-Proceeding of Engineering, vol. 5, No.1, p. 7, Mar. 2018.