

Klasifikasi Jenis Kayu Menggunakan Ekstraksi Fitur Gray Level Co-Occurrence Matrix dan Multilayer Perceptron

Deni Wahyu Wibowo*, Danang Erwanto dan Diah Arie Widhining Kusumastutie

Program Studi Teknik Elektro, Fakultas Teknik, Universitas Islam Kadiri

*Corresponding author, e-mail: deniwahyuww@gmail.com

Abstrak— Jenis kayu umumnya dicirikan dari warna, corak dan serat karena kayu secara fisik memiliki ciri yang hampir sama. Untuk menentukan jenis kayu, diperlukan pengalaman dan pengetahuan tentang kayu. Penelitian ini menerapkan teknologi pengolahan citra digital menggunakan metode ekstraksi fitur GLCM (*gray level co-occurrence matrix*) untuk menghasilkan nilai ekstraksi fitur pada tekstur kayu. Parameter nilai dihasilkan pada ekstraksi fitur GLCM adalah *correlation*, *contrast*, *energy* dan *homogeneity*. Hasil dari parameter GLCM kemudian digunakan sebagai data untuk klasifikasi jenis kayu menggunakan metode MLP (*multilayer perceptron*). Dalam penelitian ini digunakan 4 jenis kayu sebagai pengujian dan *datasheet*, yaitu kayu jati, sengon, mahoni dan mindi. Hasil dari penelitian ini, diperoleh tingkat akurasi terbaik pada data validasi sebesar 88,75 %. Keluaran dari penelitian ini berupa data *softmax* dengan menggunakan metode MLP dengan nilai *error* pada data *training* yang mendekati target sebesar 0.029421 dengan *epoch* 1.000 iterasi.

Kata Kunci : Pengolahan Citra Digital, Ekstraksi Fitur, GLCM dan MLP

Abstract— The type of wood is generally characterized by color, pattern and fiber because wood physically has almost the same characteristics. To determine the type of wood, experience and knowledge about wood are needed. This study applies digital image processing technology using the GLCM (gray level co-occurrence matrix) feature extraction method to produce feature extraction values on wood texture. The parameter values generated in the GLCM feature extraction are correlation, contrast, energy and homogeneity. The results from feature extraction are then used as a data classification of types of wood using MLP (multilayer perceptron) method. There are 4 wood types going to be involved in this research as datasets i.e., teak, sengon, mahogany, and mindi. The results of this study, obtained the best level of accuracy in validation data of 88.75%. The output of this research is softmax data using MLP method with an error value in the training neared target of data by 0.029421 with the epoch 1.000 iterations.

Keywords : Digital Image Processing, Feature Extraction, GLCM and MLP

1. Pendahuluan

Pengidentifikasian jenis kayu pada umumnya dicirikan berdasarkan ukuran, warna, serat dan corak. Pengenalan atau pengidentifikasian jenis kayu tersebut umumnya masih secara manual dengan melakukan pengamatan secara visualisasi berdasarkan ciri dari kayu tersebut.

Dalam proses pengidentifikasian jenis kayu secara manual sering terjadi kesalahan, karena kurangnya pengalaman dan pengetahuan tentang kayu. Selain itu jika dilihat secara langsung, kayu memiliki corak atau bentuk tekstur yang hampir sama sehingga waktu yang dibutuhkan untuk mengidentifikasi jenis kayu tersebut membutuhkan proses yang cukup lama, karena perlu dilakukan secara berulang-ulang dan terus-menerus untuk

memastikan kebenaran jenis kayu tersebut.

Salah satu teknik untuk melakukan pengenalan citra yang secara signifikan tidak dapat dikenali oleh mata antara lain dengan membedakan teksturnya. Tekstur dalam citra digital merupakan suatu komponen dasar dalam membentuk citra digital. Tekstur dari citra digital dapat dibedakan melalui kerapatan, keseragaman, keteraturan, kekasaran, dan lain-lain [1]. Sebuah citra RGB (*Red, Green, Blue*) memiliki unsur warna merah, warna hijau dan warna biru. Sedangkan pada citra skala keabuan (*grayscale*) memiliki unsur-unsur *entropy*, *inertia*, *energy*, dan *correlation*. Ketujuh unsur ini dapat dijadikan masukan ke sistem komputer untuk diolah lebih lanjut dalam pengenalan jenis kayu [2]. Penelitian mengenai ekstraksi fitur dari tekstur

Received date 2020-06-05, Revised date 2020-11-14, Accepted date 2020-12-03

<https://doi.org/10.25077/jnte.v10n1.788.2021>

This work is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).

kayu dengan mengkombinasikan *Gray Level Co-Occurrence Matrix* (GLCM) dan pendeteksian tepi dilakukan untuk mendapatkan karakteristik tekstur kayu [3]. Pengklasifikasian kualitas jenis kayu jati berdasarkan teksturnya dengan menggunakan metode GLCM dan Jaringan Syaraf Tiruan *backpropagation* pernah dilakukan untuk membantu sistem melakukan pengenalan pola tekstur serat dari kayu jati dengan mengambil nilai parameter korelasi, kontras, homogenitas dan energi [4].

Penelitian ini melakukan pengklasifikasian jenis kayu jati, sengon, mahoni dan mindi berdasarkan tekstur kayu dengan mengimplementasikan pengolahan citra digital menggunakan ekstraksi fitur tekstur GLCM dan algoritma *Multilayer Perceptron* (MLP) dengan tujuan menghasilkan nilai parameter ekstraksi ciri GLCM sebagai input MLP untuk mengidentifikasi jenis kayu. Metode GLCM sendiri merupakan metode yang mampu menyediakan informasi yang penting mengenai tekstur citra [5]. Informasi tekstur citra ini digunakan sebagai data masukan pada proses pengklasifikasian jenis kayu menggunakan algoritma MLP. MLP merupakan metode pembelajaran mesin (*Machine Learning*) yang mempresentasikan prinsip kerja yang hampir menyerupai system saraf pada manusia.

2. Metode

Jenis kayu biasanya ditentukan berdasarkan ukuran, warna, corak dan tekstur dari kayu itu sendiri. Setiap jenis kayu memiliki sifat fisik yang beragam. Penelitian ini merancang system yang digunakan untuk mengklasifikasikan jenis kayu jati, sengon, mahoni dan mindi berdasarkan tekstur yang dimiliki oleh masing-masing jenis kayu.

Kayu memiliki sifat istimewa, karena tidak dapat ditiru oleh bahan-bahan lain [6]. Secara umum jenis kayu dengan dibagi menjadi dua antara lain kayu daun jarum (*softwood*) atau biasa dikenal dengan *conifer* dan kayu daun lebar (*hardwood*) yang biasa disebut dengan *angiosperm* [7].

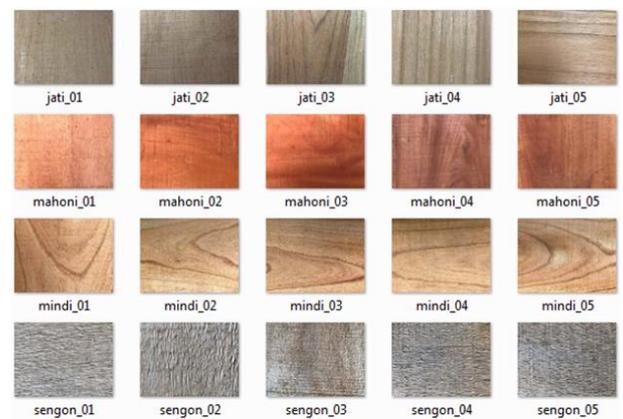
Pada penelitian ini data yang digunakan dibagi menjadi dua jenis data yaitu citra data latih dan citra data uji. Data tersebut memiliki jumlah sebanyak 400 data dengan masing-masing 100 data dari setiap jenis kayu yang diteliti dengan proporsi citra sebesar 320 x 240 pixel. Citra data latih pada penelitian ini digunakan sebagai *setting point* atau *training* pada proses pengklasifikasian program. sedangkan untuk pengujian jenis kayu pada

penelitian ini jumlah citra data testing sebanyak 80 data dengan masing-masing jenis kayu menggunakan 20 data perjenis kayu untuk keperluan akurasi. Data uji digunakan untuk *testing* program. Penentuan proporsi data untuk keperluan *training* dan validasi dilakukan secara acak atau random.

Tabel 1. Parameter data masukan

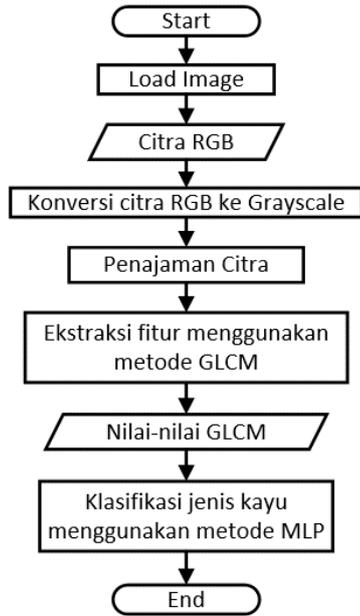
	<i>Citra Data Training</i>	<i>Citra Data Testing</i>
Jumlah Data (citra)	400	80
Resolusi (Piksel)	320 x 240	320 x 240
Ruang Warna	<i>Grayscale</i>	<i>Grayscale</i>

Citra tekstur kayu yang digunakan sebagai *datasheet* dan data validasi seperti ditunjukkan oleh gambar 1 sebagai berikut.



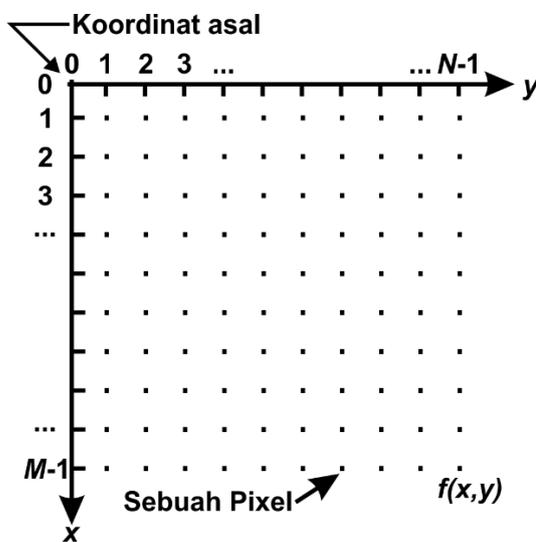
Gambar 1. Citra tekstur kayu yang digunakan sebagai *datasheet* dan data validasi

Pengambilan citra data latih menggunakan kamera ponsel yang memiliki resolusi kamera sebesar 12 *Megapixel*. Citra data latih mempunyai nilai piksel 255,0 piksel dari setiap data latih, nilai 255,0 piksel diperoleh dari proses *resize* citra asli dengan ukuran 320 x 240. Penamaan *file* dari citra data latih diseragamkan dengan format “jeniskayu_xx”, dimana xx adalah nomor urut dari file citra data latih untuk mempermudah dalam proses *checking* jika terjadi *error* atau kendala lainnya.



Gambar 2. Diagram alir system secara umum

Pengolahan citra digital digunakan untuk melakukan rekayasa dengan menggunakan komputer terhadap gambar 2 dimensi. Dalam konteks yang lebih luas, pengolahan citra digital mengacu pada pengolahan setiap data dari gambar 2 dimensi. Teknik yang dilakukan dalam pengolahan citra digital adalah melakukan manipulasi nilai pada masing-masing piksel. Citra digital merupakan sebuah larik (*array*) yang berisi nilai-nilai *real* maupun kompleks yang direpresentasikan dengan deretan bit tertentu [8]. Gambaran mengenai koordinat citra digital ditunjukkan oleh gambar 1.



Gambar 3. Koordinat Citra Digital

Citra digital juga memiliki kanal warna dasar yang membentuknya yang terdiri dari merah, hijau dan biru sehingga dikenal dengan citra RGB [9]. Bentuk persamaan matrik dari citra digital ditulis seperti pada persamaan 1 sebagai berikut [8]:

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \quad (1)$$

2.1. Konversi Citra RGB ke Grayscale

GLCM mengekstraksi fitur dari citra *grayscale* saja. Sehingga diperlukan konversi citra RGB ke *grayscale* dengan mengubah nilai kanal warna (*r*, *g* dan *b*) pada masing-masing piksel suatu citra menjadi nilai citra *grayscale* dengan nilai *s*. Proses konversi citra RGB menjadi citra *grayscale* adalah mengambil nilai rata-rata *r*, *g*, dan *b* sehingga persamaannya dapat dituliskan seperti pada persamaan 2.

$$s = \frac{r + g + b}{3} \quad (2)$$

2.2. Penajaman Citra

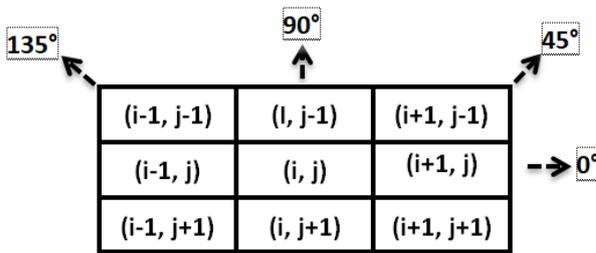
Dalam pengolahan citra digital, penajaman citra atau *image enhancement* digunakan untuk memperjelas tepi pada obyek didalam suatu citra digital. Proses yang dilakukan dalam penajaman citra adalah dengan mempertegas citra pada frekuensi tinggi (*high-pass filter*). Dengan melakukan penajaman citra menggunakan metode *high-pass filter* didapatkan citra yang memberikan kesan dari garis pola tekstur kayu lebih tegas dan selanjutnya dilakukan ekstraksi fitur menggunakan metode GLCM. Proses penajaman citra pada penelitian ini lebih berfokus pada tekstur kayu agar mendapatkan tingkat akurasi yang lebih baik dalam proses pengklasifikasiannya.

Proses penajaman pada peneliti ini menggunakan nilai parameter *r10a2* (*radius 10 amount 2*) dan *r5a1* (*radius 5 amount 2*), kemudian dibandingkan hasil pengolahan citra tersebut apakah memiliki pengaruh yang signifikan atau tidak dengan hasil keluarannya. *Amount* merupakan nilai kontras yang diaplikasikan pada kontur suatu citra di sekeliling citra objek yang akan ditajamkan. Jika nilai *amount* semakin besar maka efek penajamannya semakin tegas. *Radius* merupakan lebar kontur suatu sisi citra objek yang akan ditajamkan, jika nilai *radius* semakin besar maka sisi citra objek yang ditajamkan juga semakin lebar.

Jika nilai dari radius terlalu besar maka akan memunculkan efek halo yang mengganggu.

2.3. GLCM

GLCM merupakan suatu matriks kookurensi yang menyajikan hubungan ketetanggaan antarpiksel dalam citra dari berbagai arah orientasi dan jarak spasial. Seperti ditunjukkan oleh gambar 4, terdapat 4 sudut komputasi dalam GLCM, yaitu $\delta=0^\circ$, $\delta=45^\circ$, $\delta=90^\circ$, $\delta=135^\circ$ [10] yang menentukan arah hubungan ketetanggaan.



Gambar 4. Sudut Matrik Kookurensi

GLCM dihasilkan dengan menghitung nilai-nilai intensitas tingkat abu-abu yang ditemukan bersama dalam suatu gambar yang diberikan hubungan spasial linier antara dua piksel [11]. Fitur GLCM yang digunakan dalam penelitian adalah *contrast*, *correlation*, *energy*, *homogeneity* dan *entropy*.

2.3.1. Kontras (contrast)

Kontras merupakan suatu nilai intensitas aras keabuan antara piksel satu dengan piksel yang lainnya dengan lokasi relatif. Batas nilai dari kontras adalah 0 hingga pangkat 2 dari panjang suatu matrik GLCM simetris. Pada citra dengan elemen piksel yang memiliki nilai sama secara keseluruhan, maka nilai kontras adalah 0. Untuk mendapatkan ekstraksi fitur kontras digunakan persamaan 3 [12].

$$Cont = \sum_d \sum_y (d - y)^2 p(d, y) \tag{3}$$

Dalam perhitungan kontras, nilai p menunjukkan nilai piksel (amplitudo) dalam GLCM, sedangkan d merupakan indeks untuk elemen lateral (jejak d) dan y menunjukkan indeks untuk elemen vertikal (waktu y).

2.3.2. Korelasi (correlation)

Korelasi pada metode GLCM digunakan untuk mengukur keterkaitan linier dari aras keabuan pada suatu ketetanggaan piksel citra. Nilai ekstraksi fitur korelasi diperoleh menggunakan persamaan 4.

$$Corr = \frac{\sum_d \sum_y (d - \mu d)(y - \mu y)p(d, y)}{\sigma d \sigma y} \tag{4}$$

Dengan :

$$\mu d = \sum_d \sum_y d p(d, y) \tag{5}$$

$$\mu y = \sum_d \sum_y y p(d, y) \tag{6}$$

Dan varian GLCM adalah:

$$\sigma d = \sqrt{\sum_d \sum_y (d - \mu d)^2 p(d, y)} \tag{7}$$

$$\sigma y = \sqrt{\sum_d \sum_y (y - \mu y)^2 p(d, y)} \tag{8}$$

2.3.3. ASM (Angular Second Moment)/Energy

ASM merupakan penjumlahan pangkat dari elemen matrik GLCM. Nilai ASM akan tinggi ketika citra memiliki nilai homogenitas yang baik atau memiliki nilai piksel yang hampir serupa. Persamaan 9 digunakan untuk mencari ekstraksi fitur dari ASM.

$$Eng = \sum_d \sum_y p(d, y)^2 \tag{9}$$

2.3.4. Homogeneity

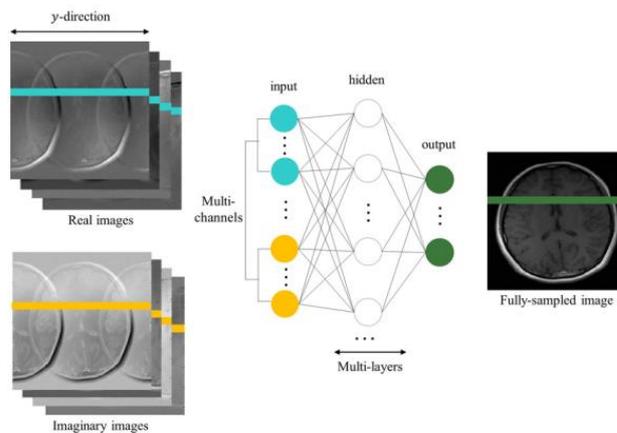
IDM (*Inverse Difference Moment*) atau biasa disebut dengan *homogeneity*/homogenitas lokal. IDM merupakan kebalikan dari bobot kontras dimana IDM akan bernilai besar jika saat ASM yang memiliki nilai tetap mempunyai nilai pixel yang sama. Persamaan 10 digunakan untuk mendapatkan nilai dari ekstraksi fitur IDM.

$$Hom = \sum_d \sum_y \frac{p(d, y)}{1 + |d - y|} \tag{10}$$

Pada penelitian ini vektor *contras*, *correlation*, *energy*, dan *homogeneity* digunakan untuk menginterpretasikan tekstur citra. Pada dasarnya setiap fitur memiliki fungsi yang berbeda-beda tergantung pada penggunaannya.

2.4. MLP (Multilayer Perceptron)

Jaringan Saraf Tiruan (JST) adalah suatu model pengolahan informasi yang terinspirasi dari sistem sel syaraf biologi dan layaknya seperti otak yang mengolah suatu informasi. JST bersifat intensif komputasi dan intensif memori, membuatnya sulit untuk digunakan pada sistem tertanam/*Embedded System* [13]. MLP merupakan topologi paling umum dari JST. MLP banyak digunakan dalam berbagai aplikasi klasifikasi dan regresi dalam berbagai bidang pengenalan suara, pola dan masalah klasifikasi lainnya. Pada MLP *perceptron-perceptron* terhubung membentuk beberapa lapisan (*layer*). Sebuah MLP mempunyai lapisan masukan (*input layer*), minimal satu lapisan tersembunyi (*hidden layer*), dan lapisan luaran (*output layer*) [14].



Gambar 5. Arsitektur MLP [15]

Setelah proses ekstraksi menggunakan metode GLCM maka nilai vektor yang dihasilkan diberikan label bilangan sesuai dengan klasifikasi yang telah ditentukan. Pada setiap data *training* jenis kayu memiliki jumlah 100 data per jenis kayu yang akan diklasifikasi.

Pada penelitian ini menggunakan 3 lapisan *hidden layer* dengan model arsitektur metode MLP seperti gambar 5. Jumlah *neuron* pada *hidden layer* pertama sebanyak 20 *neuron*, jumlah *neuron hidden layer* kedua 30 *neuron*, dan jumlah *neuron hidden layer* ketiga sebanyak 4 *neuron* dengan jumlah *epoch* yang akan digunakan sebesar 1.000 kali. Dalam penelitian ini menggunakan fungsi

aktivasi jenis *tansig* (fungsi sigmoid bipolar) yang dijadikan data *output* dari pengolahan algoritma MLP.

Error keluaran *output layer* dihitung dengan cara mencari selisihnya nilai target yang ada dalam data *training* dengan nilai *output* dari neuron pada *output layer* seperti pada persamaan 11 berikut.

$$E_k = t_k - y_k \tag{11}$$

Dimana E_k merupakan nilai *error*, t adalah nilai target pada data *training* dan y merupakan nilai *output* dari neuron pada *output layer* (y_k). Jika *output layer* terdiri dari beberapa neuron maka *error* dihitung pada setiap neuron. Sedangkan faktor koreksi pada *output layer* (δ_k), dihitung menggunakan persamaan 12 sebagai berikut.

$$\delta_k = E_k \cdot \delta_k \cdot Z_j \tag{12}$$

Dimana Z_j adalah *hidden layer*. Jika *output layer* terdiri dari beberapa neuron maka *error* dihitung pada setiap neuron. Untuk faktor perubahan bobot diantara *output layer* dan *hidden layer* (Δv_{jk}) dapat dicari engan menggunakan persamaan 13 sebagai berikut.

$$\Delta v_{jk} = \alpha \cdot y_k (1 - y_k) \tag{12}$$

Dimana α merupakan *learning rate*/laju pdengan rentang 0 – 1. Sehingga faktor koreksi pada *hidden layer* (δ_k) dihitung menggunakan persamaan 14 dan 15 sebagai berikut.

$$\delta_j = \delta_{netj} \cdot Z_j (1 - Z_j) \tag{14}$$

Dimana,

$$\delta_{netj} = \sum_{k=1}^M \delta_k \cdot V_{jk} \tag{15}$$

Dalam klasifikasi jenis neural network biasanya menggunakan parameter MSE (*Mean Squared Error*) dan akurasi untuk evaluasi *training*. MSE sendiri merupakan parameter untuk mengevaluasi data *training*. Nilai MSE merupakan kuadrat dari jumlah selisih antara target (t) dengan nilai *output layer* (y_k) pada setiap iterasi/pengulangan (i) dibagi dengan jumlah iterasi maksimumnya (n) sebagaimana ditunjukkan oleh persamaan 16.

$$MSE = \frac{\sum(t_i - y_{ki})^2}{n} \quad (16)$$

Data keluaran yang dihasilkan dari algoritma MLP berupa nilai prediksi dan nilai data *softmax* hasil klasifikasi yang menampilkan hasil dari nilai tertinggi yang didapat dari nilai prediksi. Nilai yang memiliki angka tertinggi dari hasil kemungkinan merupakan hasil dari pengklasifikasian tersebut. Data *softmax* dari pengolahan MLP menghasilkan nilai pada setiap jenis kayu kemudian dari hasil *output* tersebut dicari nilai tertinggi daripada hasil *output* yang lain. Dari data *softmax* tersebut menghasilkan satu jenis klasifikasi yang ditampilkan dari empat jenis kayu yang diteliti, keluaran akhir pada penelitian ini adalah keterangan jenis kayu.

Persentase akurasi dapat dihitung dengan cara membagi jumlah prediksi benar (y_b) dengan total data training (m) dan dikalikan dengan 100% sebagaimana disajikan oleh persamaan 16.

$$Accuracy = \frac{\sum y_b}{m} \times 100\% \quad (16)$$

3. Hasil dan Pembahasan

Analisis data penelitian ini menjelaskan hasil dari pengolahan citra dengan metode GLCM dan MLP mulai pembentukan *datasheet*, mengonversi citra *input*, pengolahan ekstraksi GLCM, hasil prediksi dari pengolahan klasifikasi MLP sampai hasil klasifikasi berupa data *softmax*. Gambar 6 adalah tampilan antarmuka sistem untuk klasifikasi jenis kayu menggunakan metode GLCM dan MLP.

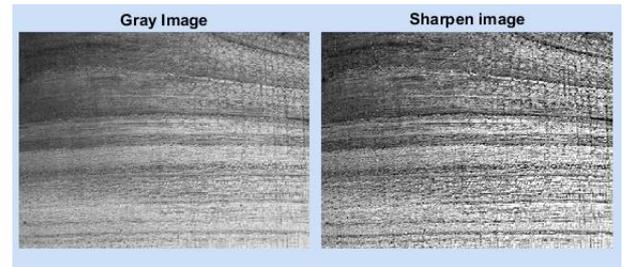


Gambar 6. Tampilan Interface GUI

3.1. Penajaman Citra

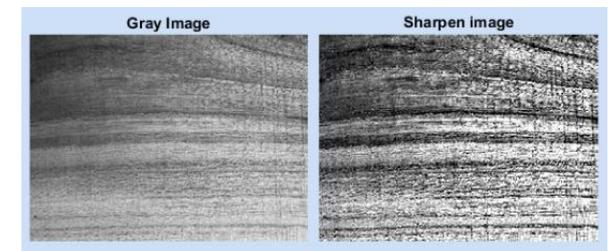
Citra *input* pada penelitian ini berupa citra RGB yang diubah ke citra *grayscale*, dan kemudian ditajamkan dengan proses penajaman citra dengan menggunakan 2 pilihan dalam penerapan nilai parameter, yaitu dengan parameter nilai *radius* 5 dan *amount* 1 dan parameter kedua dengan nilai

radius 10 dan *amount* 2 dengan hasil uji coba seperti gambar 7.



Gambar 7. Hasil *Unmask* pada *Radius* 5, *Amount* 1

Dengan perbandingan parameter sebesar 1:2, maka pada penerapan parameter kedua digunakan nilai *radius* 10 dan *amount* 2, sehingga didapatkan hasil seperti gambar 8.



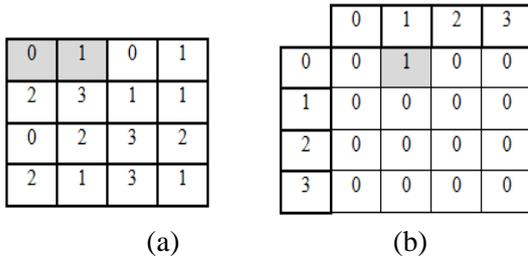
Gambar 8. Hasil *unmask* pada *Radius* 10, *Amount* 2

Pada penelitian ini digunakan nilai parameter untuk penajaman citra dengan *radius* 10 dan *amount* 2 karena pada parameter tersebut menghasilkan citra serat kayu yang lebih presisi dan terlihat lebih jelas citra tekstur kayunya dibandingkan dengan parameter sebelumnya.

3.2. Ekstraksi Fitur GLCM

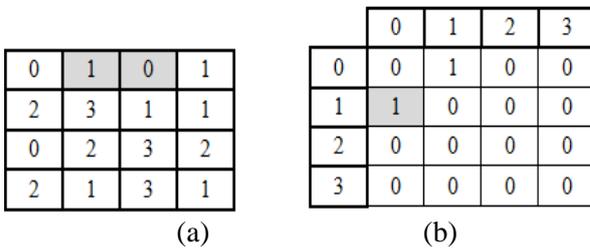
Gambar 9a, 10a dan 11a merupakan matrik awal yang dibentuk dari citra *grayscale* kemudian dilakukan kuantisasi menjadi 4 level skala keabuan (0 – 3). Pembuatan matrik ketetangaan (Gambar 9b, 10b dan 11b) berdasarkan matrik awal dengan menggunakan orientasi sudut (θ) 0° dan jarak (d) sebesar 1 piksel.

Korelasi antar piksel dengan sudut ketetangaan 0° didapatkan pada piksel pada koordinat (0,0) dengan piksel pada koordinat (0,1) dan pasangan ketetangaan koordinat (0,1) pada matriks *framework* bertambah 1 ditunjukkan oleh gambar matriks ketetangaan sebagai berikut.



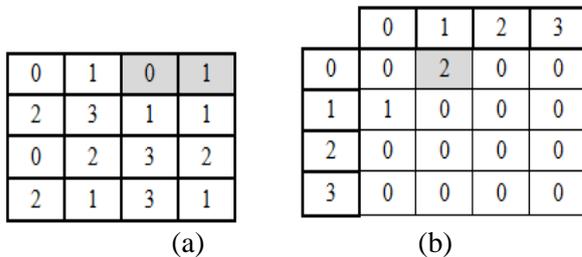
Gambar 9. a. matrik awal, b. Matriks Ketetangaan Pixel koordinat (0,1) Bertambah 1

Korelasi antar piksel dengan sudut ketetangaan 0° yaitu pada piksel koordinat (0,1) dengan piksel koordinat (0,2). Pasangan ketetangaan koordinat (1,0) pada matriks *framework* GLCM bertambah 1 ditunjukkan oleh gambar matriks ketetangaan sebagai berikut.



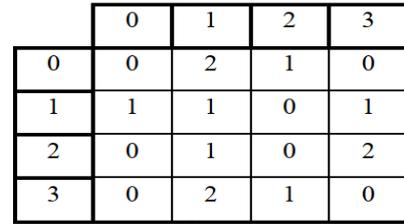
Gambar 10. a. matrik awal, b. Matriks Ketetangaan Pixel koordinat (1,0) Bertambah 1

Korelasi antar piksel dengan sudut ketetangaan 0° yaitu pada piksel koordinat (0,2) dengan piksel koordinat (0,3). Pasangan ketetangaan kordinat (1,0) pada matriks *framework* GLCM bertambah 1 sehingga menjadi 2 ditunjukkan oleh gambar matriks ketetangaan sebagai berikut.



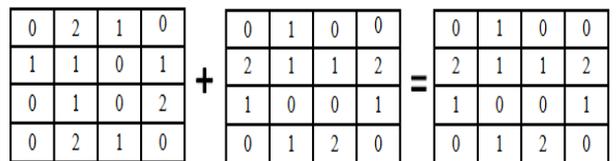
Gambar 11. a. matrik awal, b. Matriks Ketetangaan Pixel koordinat (0,1) Bertambah menjadi 2

Demikian proses tersebut berulang hingga baris ke-4 sehingga diperoleh matriks GLCM pada sudut 0° seperti gambar 12 sebagai berikut.



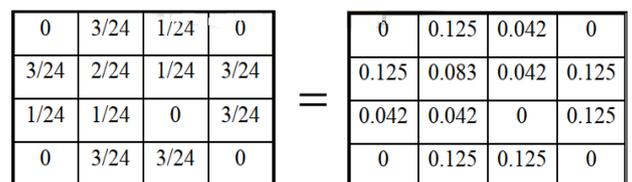
Gambar 12. Matriks 4 × 4 Dengan Sudut 0°

Penjumlahan matriks GLCM seperti yang ditunjukkan oleh gambar 13 yaitu menggunakan *transpose* dari matriks itu sendiri sehingga menghasilkan matriks simetris. Kemudian matriks GLCM simetris tersebut dinormalisasi sehingga dapat dianalisis dengan menghitung masing-masing ekstraksi fiturnya.



Gambar 13. Matriks simetris hasil penjumlahan matriks GLCM 4 × 4 simetris sudut 0° dengan *transpose*-nya

Dari matriks GLCM simetris melewati proses normalisasi, masing-masing nilai pada piksel matriks dibagi dengan jumlah piksel ketetangaan. Gambar 14 merupakan matrik yang melewati proses normalisasi dengan membagi matriks simetris dengan jumlah piksel ketetangaan berjumlah 24, sehingga masing-masing nilai piksel GLCM tersebut dibagi 24.



Gambar 14. Matriks GLCM 4 × 4 Sudut 0° Setelah Dinormalisasi

Dari normalisasi, nilai ekstraksi ciri pada piksel matriks GLCM 4 × 4 dapat diamati melalui tabel 2 sebagai berikut dimana nilai piksel 0 tidak dihitung.

Tabel 2. Nilai Piksel Matriks GLCM

Koordinat GLCM	Nilai
(1,2)	0.125
(1,3)	0.042
(2,1)	0.125
(2,2)	0.083
(2,3)	0.042
(2,4)	0.125
(3,1)	0.042
(3,2)	0.042
(3,4)	0.125
(4,2)	0.125
(4,3)	0.125

Dari nilai piksel matriks GLCM masing-masing koordinat, dihitung nilainya parameter kelima fitur GLCM (kontras, korelasi, energi, IDM dan entropi) sehingga hasilnya sebagaimana disajikan oleh tabel 3.

Tabel 3. Nilai Parameter ekstraksi ciri GLCM 4x4 pada orientasi 0°

Fitur GLCM	Nilai Parameter
Kontras	0,192
Korelasi	0,1047
Energi	0,4418
IDM	0,1076
entropi	0,9973

Sedangkan nilai kontras, korelasi, energi dan IDM pada masing-masing citra disajikan oleh tabel 4 berikut ini.

Tabel 4. Parameter data masukan

Nama Data	Nilai Parameter GLCM			
	Kontras	Korelasi	Energi	IDM
Jati_01	14616,7	0.00585992	0,0000146	0,311126
Jati_02	14634,7	-0,0004245	0,0000146	0,0312621
Jati_03	14770,8	-0,0002869	0,0000154	0,0306497
Jati_04	15766,4	0,0036545	0,0000149	0,0309095
Jati_05	14539,8	0,0033195	0,000015	0,0309805
Sengon_01	15270,7	-0,0017245	0,0000174	0,030996
Sengon_02	14927	0,0022582	0,0000171	0,0310668
Sengon_03	15079,5	-0,0002618	0,0000154	0,0310239
Sengon_04	14371,1	0,0102746	0,0000184	0,0312018
Sengon_05	15162,2	0,0005629	0,0000182	0,0313041
Mahoni_01	14607,7	0,0050828	0,0000153	0,0311818
Mahoni_02	15542,7	-0,0031322	0,0000176	0,0304796
Mahoni_03	15454,5	0,0007906	0,0000152	0,0307979
Mahoni_04	14741,6	-0,0016068	0,0000158	0,0309774
Mahoni_05	15402,9	0,0016656	0,000016	0,0308315
Mindi_01	15501,1	0,0070064	0,0000171	0,0309018
Mindi_02	14980	-0,0015536	0,0000151	0,0311361
Mindi_03	15268,9	-0,0022588	0,0000151	0,0308615
Mindi_04	14614,7	0,0029865	0,0000153	0,0312882
Mindi_05	15301,1	0,001841	0,0000148	0,0310061

Dalam penelitian ini, nilai *entropy* tidak digunakan sebagai masukan dalam proses klasifikasi.

3.3. MLP

Metode klasifikasi MLP pada penelitian ini menggunakan *hidden layer* sebanyak 3 dengan jumlah *neuron* disetiap *hidden layer*-nya adalah 20, 30 dan 4 *neuron* dengan tipe data aktivasi berupa data *tansiq*, yaitu tipe data yang mempunyai range *output* dari nilai -1 sampai 1. Dan pada proses MLP peneliti menggunakan nilai biner sebagai *vector output* pada masing-masing jenis kayu yang sebagai proses *labeling* data untuk dijadikan data target. Nilai biner vektor *output* seperti tabel 5 berikut.

Tabel 5. Nilai Biner Vektor Input

Klasifikasi	Vector Output
Kayu jati	[1 0 0 0]
Kayu sengon	[0 1 0 0]
Kayu mahoni	[0 0 1 0]
Kayu mindi	[0 0 0 1]

Hasil dari klasifikasi MLP diperoleh nilai prediksi yang merupakan hasil dari pengolahan klasifikasi MLP menggunakan 3 *hidden layer* dan memiliki jumlah *neuron* 20 30 4. Sesuai dengan nilai biner vektor *input* dari tabel 5 diterapkan proses *softmax* dan menghasilkan data seperti tabel 6 berikut.

Tabel 6. Hasil Nilai Prediksi

No	Nilai Prediksi				Hasil Softmax	Hasil Output
	Jati	Sengon	Mahoni	Mindi		
1	0,92123	0,02857	0,05864	0,06822	0,92123	Jati
2	0,68187	0,21035	-0,00010	-0,05818	0,68187	Jati
3	0,97929	-0,04637	0,01847	0,02498	0,97929	Jati
4	0,97589	0,04418	-0,00826	-0,12474	0,97589	Jati
5	0,95873	0,06325	0,09188	0,07829	0,95873	Jati
6	0,05743	0,70304	-0,13723	-0,16657	0,70304	Sengon
7	0,20126	0,55512	-0,00465	0,22425	0,55512	Sengon
8	-0,09419	0,99602	0,01017	0,06533	0,99602	Sengon
9	0,09152	0,99045	0,10759	0,11056	0,99045	Sengon
10	-0,00682	0,99416	-0,01379	0,00668	0,99416	Sengon
11	0,07238	-0,20146	0,94309	0,04675	0,94309	Mahoni
12	-0,06472	-0,22398	0,97814	-0,01594	0,97814	Mahoni
13	0,00290	0,05120	0,98754	-0,00226	0,98754	Mahoni
14	-0,03361	0,10500	0,94100	-0,00069	0,94100	Mahoni
15	-0,04789	-0,09690	0,98526	0,08045	0,98526	Mahoni
16	-0,14233	-0,03490	-0,00227	0,89850	0,89850	Mindi
17	-0,14233	-0,03490	-0,00227	0,89850	0,89850	Mindi
18	0,06401	-0,05954	0,00011	0,95628	0,95628	Mindi
19	0,06401	-0,05954	0,00011	0,95628	0,95628	Mindi
20	-0,12654	0,20452	0,00367	0,85913	0,85913	Mindi

Hasil *output* berupa data *softmax* yang didapat dari nilai prediksi. Hasil akhir menghasilkan klasifikasi jenis kayu yang dideteksi berupa jenis kayu.

3.4. Hasil pengujian

Penelitian ini menggunakan data uji yang memiliki jumlah data sebanyak 80 data. Dari data uji tersebut per jenis kayu memiliki 20 data uji, dan proporsi data sama dengan data latih, yakni 320×240 piksel. Dari pengujian didapatkan tabel hasil data uji untuk mencari persentase keberhasilan pengujian seperti tabel dibawah ini.

Tabel 7. Persentase Keberhasilan Pengujian

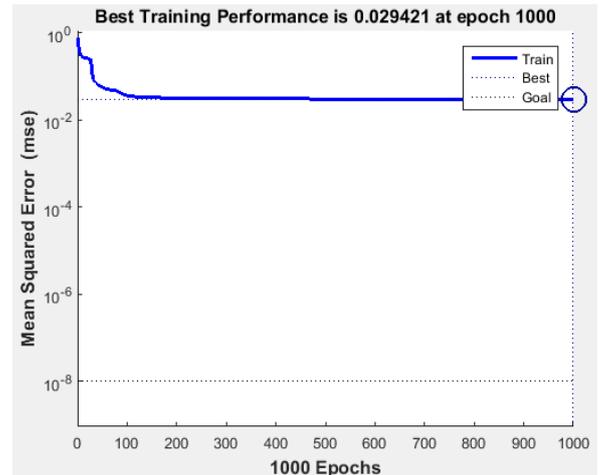
No	Kategori Percobaan	Total	Hasil Klasifikasi		% Keberhasilan Per jenis kayu
			Benar	Salah	
1.	Kayu Jati	20	19	1	95 %
2.	Kayu Sengon	20	17	3	85 %
3.	Kayu Mahoni	20	18	2	90 %
4.	Kayu Mindi	20	17	3	85 %
Total Data		80	31	9	-
% Rata-rata keberhasilan data					88,75%

Dari data persentase keberhasilan pengujian yang disajikan oleh tabel 7 dapat disimpulkan bahwa persentase keberhasilan pada data uji mencapai 88,75% dari total keseluruhan data sebanyak 80 data dengan rincian percobaan data per jenis kayu 20 data. Semua citra data uji tersebut berukuran 320×240 piksel.

Analisa dari hasil persentase pada tabel diatas menunjukkan bahwa kayu jenis jati dan mahoni menghasilkan nilai persentase diatas rata-rata dikarenakan jenis kayu jati dan mahoni memiliki citra *datasheet* yang baik dan pada saat proses pemfilteran data *train* jenis kayu tersebut memiliki nilai tertinggi dalam data target, dimana pada data target pada penelitian adalah 96% (nilai persentase yang diambil pada data *train*), akan tetapi pada hasil data validasi persentase nilai akurasi menjadi rata-rata 88,75%, menurun sebesar 7,25% dikarenakan pada jenis kayu sengon dan mindi memiliki nilai persentase dibawah rata-rata dengan hasil sebesar 85% yang dimungkinkan pada citra data kayu tersebut memiliki nilai parameter yang hampir sama jadi pada klasifikasi lebih cenderung diklasifikasi jenis kayu yang berbeda.

Dari pengujian ini menghasilkan tingkat akurasi dari penerapan metode GLCM dengan *pre-processing* (konversi citra RGB ke *grayscale* dan penajaman citra tekstur) kemudian diklasifikasi

dengan menggunakan metode MLP mendapatkan nilai keberhasilan data sebesar 88,75%.



Gambar 12. Hasil performa data *training*

Pada gambar 12 diatas merupakan hasil MSE dari data *training* yang diproses dengan metode MLP, dengan hasil terbaik dari kinerja data *training* untuk dapat mengklasifikasikan dari 4 jenis kayu tersebut dari performa terbaik (jaringan nilai *error* yang paling mendekati target) sebesar 0.029421 dengan *epoch* sebesar 1.000.

4. Kesimpulan

Proses ekstraksi fitur menggunakan metode GLCM pada masing-masing citra kayu jati, sengon, mahoni dan mindi dengan penajaman citra pada nilai *radius* 10 dan *amount* 2 dapat menghasilkan nilai parameter GLCM berupa *correlation*, *contrast*, *energy* dan *homogeneity* yang bervariasi.

Penerapan metode MLP untuk klasifikasi citra kayu jati, sengon, mahoni dan mindi pada penelitian ini dapat berjalan dengan baik dengan jumlah *neuron* sebanyak 20, 30 dan 4 *neuron* pada *hidden layer* dan menghasilkan akurasi sistem pada data *train* sebesar 96%. Pada saat pengujian data validasi, tingkat akurasi menurun sebesar 7,25%.

Daftar Pustaka

- [1] I. Santoso, Y. Christyono, and M. Indriani, "Kinerja Pengenalan Citra Tekstur menggunakan Analisis Tekstur Metode Run Length," in *Seminar Nasional Aplikasi Teknologi Informasi (SNATI)*, 2007.
- [2] I. Gunawan, J. Halomoan, and R. D. Atmaja, "Perancangan Sistem Identifikasi Kualitas Kayu Untuk Quality Kontrol Berbasis Pengolahan Citra Digital," *eProceedings Eng.*,

- vol. 2, no. 1, 2015.
- [3] A. Fahrurrozi, S. Madenda, D. Kerami, and others, "Wood texture features extraction by using GLCM combined with various edge detection methods," in *Journal of Physics: Conference Series*, 2016, vol. 725, no. 1, p. 12005.
- [4] M. I. Fathurrahman, J. Jondri, and A. A. Rohmawati, "Sistem Klasifikasi Kualitas Kayu Jati Berdasarkan Jenis Tekstur Dengan Jaringan Syaraf Tiruan Menggunakan Gray-level-co-occurrence Matrix," *eProceedings Eng.*, vol. 6, no. 2, 2019.
- [5] A. W. Sanjaya, "Deteksi Penyakit Kulit Menggunakan Analisis Fitur Warna dan Tekstur Dengan Metode Color Moment, Gray Level Cooccurrence Matrix dan Jaringan Saraf Tiruan Backpropagation," *Inst. Teknol. Telkom*, 2011.
- [6] J. F. Dumanauw, *Mengenal Kayu <EDISI BARU>*. Kanisius.
- [7] R. A. Pramunendar, D. P. Prabowo, D. Pergiwati, and K. Latifa, "KLASIFIKASI JENIS KAYU MENGGUNAKAN BACK-PROPAGATION NEURAL NETWORK BERDASARKAN FITUR GRAY LEVEL COOCCURRENCE MATRIX," *Sens 3*, vol. 1, no. 1, 2017.
- [8] D. Putra, *Pengolahan citra digital*. Penerbit Andi, 2010.
- [9] M. A. Afandi, S. I. Purnama, and R. F. Crisianti, "Implementasi Metode Deteksi Tepi Laplacian dan Jarak Euclidean untuk Identifikasi Tanda Tangan," *J. Nas. Tek. Elektro*, vol. 9, no. 1, pp. 34–43, 2020.
- [10] S. Santosa, M. Martono, M. B. Utomo, and B. S. Budi, "Seleksi Arah Sudut Komputasi Dan Fitur Glcm Pada Kstraksi Citra Kayu Jati, Mahoni, Mindi, Dan Sengon," *Wahana Tek. Sipil J. Pengemb. Tek. Sipil*, vol. 23, no. 2, pp. 77–87, 2019.
- [11] K. Lloyd, P. L. Rosin, D. Marshall, and S. C. Moore, "Detecting violent and abnormal crowd activity using temporal analysis of grey level co-occurrence matrix (GLCM)-based texture measures," *Mach. Vis. Appl.*, vol. 28, no. 3–4, pp. 361–371, 2017.
- [12] O. R. Indriani, E. J. Kusuma, C. A. Sari, E. H. Rachmawanto, and others, "Tomatoes classification using K-NN based on GLCM and HSV color space," in *2017 international conference on innovative and creative information technology (ICITech)*, 2017, pp. 1–6.
- [13] S. Han, J. Pool, J. Tran, and W. Dally, "Learning both weights and connections for efficient neural network," in *Advances in neural information processing systems*, 2015, pp. 1135–1143.
- [14] N. Purwaningsih, "Penerapan Multilayer Perceptron Untuk Klasifikasi Jenis Kulit Sapi Tersamak," *J. Teknolf*, vol. 4, no. 1, 2016.
- [15] K. Kwon, D. Kim, and H. Park, "A parallel MR imaging method using multilayer perceptron," *Med. Phys.*, vol. 44, no. 12, pp. 6209–6224, 2017.