

## SISTEM KLASIFIKASI KUALITAS KAYU JATI BERDASARKAN JENIS TEKSTUR DENGAN JARINGAN SYARAF TIRUAN MENGGUNAKAN GRAY-LEVEL-CO-OCCURENCE MATRIX

Muhammad Irfan Fathurrahman<sup>1</sup>, Drs. Jondri. M. Si<sup>2</sup>, Aniq Atiqi Rohmawati M. Si<sup>3</sup>

<sup>1,2,3</sup>Fakultas Informatika, Universitas Telkom, Bandung

<sup>1</sup>irfanfath@student.telkomuniversity.ac.id, <sup>2</sup>jondri@telkomuniversity.ac.id, <sup>3</sup>aniqatiqi@telkomuniversity.ac.id

---

### Abstrak

Kayu jati memiliki karakteristik akan kekuatan yang dimilikinya dalam ketahanan berbagai perubahan cuaca. Kayu jenis ini banyak dimanfaatkan dalam keperluan rumah tangga atau kebutuhan perindustrian lainnya. Selain itu memiliki karakter tekstur dan serat yang menjadi ciri khas tersendiri. Secara kasat mata mungkin akan sulit membedakan jenis kualitas kayu jati ini. Citra kayu dapat dibedakan dengan jenis tekstur serat. Identifikasi ini dapat dilakukan dengan proses analisis citra kayu, pemrosesan citra, identifikasi ciri, dan kemudian pengklasifikasian. Identifikasi ciri ini menggunakan *Gray-level-co-occurrence (GLCM)* kemudian melakukan klasifikasi dengan jaringan syaraf tiruan. Metode ini digunakan untuk membantu sistem melakukan pengenalan pola tekstur serat melalui nilai kontras, korelasi, homogenitas dan energy. Keluaran yang dihasilkan memiliki akurasi sebesar 98,3%. Dari 60 data yang diujikan pada sistem hanya terdapat 2 kesalahan antara data asli dan data hasil pengujian.

**Kata kunci:** Identifikasi kualitas kayu jati, Gray Level Coocurence Matrix, Jaringan Syaraf Tiruan, Jaringan Syaraf Tiruan propagasi balik

---

### Abstract

Teak having the characteristics of the property in the resistance of a variety of climate change. This type of wood commonly used in domestic use or need other industry. Besides having the character texture and fiber is typical of its own. In naked eyes may be hard to differentiate teak this kind of the quality. The image of wood can be distinguished by a kind of texture fibers. This can be done by identification image analysis wood, image processing, the identification, and then classification. It uses the identification gray-level-co-occurrence ( *glcm* ) classification in the artificial neural network. This method used to help the system did pattern recognition texture through the value of the contrast, correlation, homogeneity and energy. Output has produced by 98,3% accuracy. From 60 data to be tested in the system only have 2 error of the data between real data and the result of testing

**Keywords:** identification teak quality, Gray Level Co-Occurrence Matrix, Artificial Neural Network, Artificial Neural Network Backpropagation

---

### 1. Pendahuluan

Tanaman jati merupakan tanaman tropika dan sub tropika yang sejak abad ke-9 telah dikenal sebagai pohon yang memiliki kualitas tinggi dan bernilai jual tinggi. Tanaman jati yang tumbuh di Indonesia berasal dari India [1]. Selain itu kayu jati pun memiliki beberapa kelas dalam kualitasnya. Dengan perkembangan teknologi pada zaman ini, untuk membedakan jenis kayu dapat dibantu dengan sistem komputer. Untuk melakukan klasifikasi tentu harus memiliki pengetahuan yang cukup dalam mengenai tekstur dan serat kayu. Bagi manusia yang masih awam tentu akan kesulitan untuk membedakan secara kasat mata. Sehingga dikembangkan suatu sistem teknik klasifikasi untuk identifikasi jenis kayu dengan metode GLCM. Metode ini merupakan suatu metode yang melakukan analisis terhadap suatu piksel pada citra dan mengetahui tingkat keabuan yang sering terjadi. Metode ini menganalisis frekuensi pada kombinasi nilai piksel yang muncul pada suatu citra. Untuk melakukan analisis citra berdasarkan distribusi statistik dari intensitas pikselnya, dapat dilakukan dengan mengekstrak fitur teksturnya [2]. Metode yang digunakan meliputi analisis citra warna keabuan dan *Gray Level Cooccurrence Matrix (GLCM)* untuk analisis fitur tekstur serat kayu. Metode GLCM sendiri merupakan metode yang mampu menyediakan informasi yang penting mengenai tekstur citra [3]. Untuk klasifikasi yang digunakan sistem adalah Jaringan Saraf Tiruan (JST) *Backpropagation* karena mampu digunakan untuk menyelesaikan *problem non linier* termasuk pengenalan pola [3]. Tujuan dari penelitian ini adalah untuk melakukan pengklasifikasian jenis kualitas kayu dengan menggunakan jaringan syaraf tiruan. Algoritma ini dipilih karena kemampuannya yang memiliki kecenderungan untuk menyimpan pengetahuan yang dialami dan dapat

digunakan kembali. Jaringan syaraf tiruan menyerupai otak manusia dengan cara menyimpan pengetahuan yang diperoleh jaringan dari pelatihannya melalui proses pembelajaran dan kekuatan hubungan antar neuron,


## 2. Studi Terkait

### 2.1. Studi literatur

Klasifikasi terhadap objek citra kayu dapat menggunakan metode k-Nearest Neighbour (kNN). kNN melakukan klasifikasi berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek tersebut [25]. naive bayes merupakan suatu teknik yang dapat digunakan untuk teknik klasifikasi. Terdapat beberapa penelitian yang dilakukan terhadap klasifikasi dengan menggunakan data sebuah citra. Penelitian tersebut disebutkan bahwa proses klasifikasi menggunakan KNN membuahkan hasil yang cukup baik[25]. Sementara penelitian lainnya menyatakan bahwa penelitian tentang kayu masih jarang dilakukan. Pada penelitian ini dituliskan bahwa peneliti menggunakan metode klasifikasi KNN dengan nilai akursai lebih dari 12% [26].

### 2.2. Ekstraksi fitur

Ekstraksi fitur merupakan salah satu bagian dalam proses analisis suatu citra. Fitur sendiri merupakan karakteristik unik dari suatu objek yang diamati. Salah satu metode ekstraksi fitur adalah Gray Level Co-occurrence Matrix (GLCM). Gray Level Co-occurrence Matrix adalah suatu matriks yang elemen-elemennya merupakan jumlah dari pasangan piksel yang memiliki tingkat kecerahan tertentu, dimana pasangan piksel tersebut terpisah dengan jarak dan sudut [23]. Orientasi sudut terbentuk berdasarkan empat arah sudut yaitu,  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  dan  $135^\circ$ , dan jarak antar piksel sebesar 1 piksel [22]. Nilai *input* dari GLCM adalah sebuah matriks yang merupakan representasi dari citra *grayscale*, keluaran dari GLCM adalah berupa matriks kookurensi yang kemudian dapat kita ekstrak cirinya berdasarkan parameter ciri statistik orde dua seperti kontras, korelasi, homogenitas dan energi.



Gambar 1. Ilustrasi Sudut Dalam GLCM

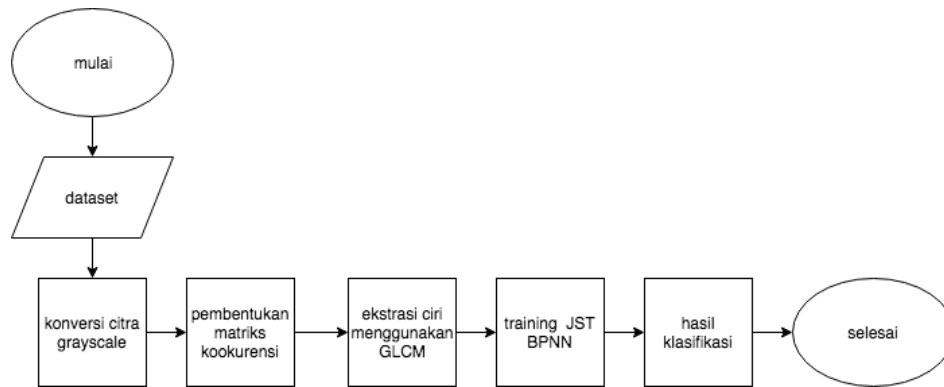
### 2.3. Jaringan Syaraf Tiruan

Jaringan syaraf tiruan adalah sebuah mesin yang dirancang untuk memodelkan cara otak manusia mengerjakan fungsi atau tugas-tugas tertentu. Mesin ini memiliki kemampuan menyimpan pengetahuan berdasarkan pengalaman dan menjadikan simpanan pengetahuan yang dimiliki menjadi bermanfaat[24]. Jaringan Syaraf Tiruan dibentuk untuk memecahkan suatu masalah tertentu seperti pengenalan pola atau klasifikasi karena proses pembelajarannya yang menirukan cara kerja dari sistem syaraf biologi dengan model struktur dari otak. Jaringan syaraf tiruan ditentukan oleh 3 parameter, antara lain arsitektur jaringan, bobot penghubung atau metode pelatihan serta fungsi aktivasi

## 3. Sistem yang Dibangun

### 3.1. Gambaran Umum Sistem

Sistem menggunakan proses ekstraksi ciri dengan metode GLCM, proses input nilai  $x$ , proses training JST BPNN, dan yang terakhir adalah proses klasifikasi untuk mendapat keluaran hasil klasifikasi. Untuk data input terdapat dua bagian yaitu data uji dan data train. Data latih digunakan saat proses training JST Backpropagation dan data uji digunakan saat proses klasifikasi. Data train yang digunakan adalah citra yang sudah dikonversi ke nilai matriks. Sistem yang dibangun pada penelitian ini digambarkan pada Gambar 3:



**Gambar 2. Gambaran Umum Alur Sistem**

### 3.2 Dataset

Dataset yang digunakan merupakan kayu dengan 4 jenis kelas, yaitu kelas A, kelas B, kelas C, dan kelas D. Contoh data dapat dilihat pada Tabel 1. Dataset ini terbagi menjadi 2 bagian yaitu data latih untuk proses *learning* pada klasifikasi, dan data uji untuk menguji hasil klasifikasi. Data uji inilah yang kemudian akan dilakukan pengklasifikasian kelas. Dataset yang dimiliki dalam bentuk gambar, maka akan dilakukan ekstraksi ciri melalui tekstur serat menggunakan GLCM.

**Table 1. Dataset**

Item	Data Latih	Data Uji
Grade A	24	5
Grade B	24	5
Grade C	24	5
Grade D	24	5

Gambar citra yang dimiliki sebagai berikut :



**Gambar 3. Grade A**



**Gambar 4. Grade B**




**Gambar 5. Grade C**



**Gambar 6. Grade D**

### **3.3 Ekstraksi Ciri**

Suatu proses klasifikasi citra berbasis analisis pada umumnya membutuhkan ekstraksi ciri. Ekstraksi ciri statistik orde kedua dilakukan dengan matriks kookurensi, yaitu suatu matriks antara yang merepresentasikan hubungan ketetangaan antar piksel dalam citra pada berbagai arah orientasi dan jarak spasial. Untuk memperoleh ciri statistik orde dua adalah dengan menghitung probabilitas hubungan ketetangaan antara dua piksel pada jarak dan orientasi sudut tertentu. Pendekatan ini bekerja dengan membentuk sebuah matriks kookurensi dari data citra, dilanjutkan dengan menentukan ciri sebagai fungsi dari matriks tersebut.



**Gambar 7. Ilustrasi Ekstraksi Ciri Statistik Matriks Kookurensi**

Suatu citra berukuran  $N \times M$  pixel dengan intensitas beragam pada tiap pixelnya, direpresentasikan secara numerik dengan matriks terdiri dari  $N$  baris dan  $M$  kolom. Hubungan antar pixel adalah hal yang sangat penting dalam menentukan batas wilayah suatu obyek. Untuk menentukan apakah 2 piksel saling berhubungan, maka harus ditentukan terlebih dahulu apakah 2 piksel tersebut saling berhimpitan. Untuk menentukan 2 piksel yang saling berhimpitan menggunakan sudut rotasi dan jarak antar piksel atau disebut *pixel distance*. Proses ini dilakukan 4 kali dengan letak tetangga yang berbeda-beda yaitu  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  dan  $135^\circ$ . Sebagai contoh, pada table 2 diketahui masukan citra *array* berukuran  $8 \times 8$  piksel 8 derajat keabuan dengan rentang nilai (0, 7) :

**Table 2. Matriks Array 8 x 8**

1	1	5	5	0	0	1	0
1	1	2	2	0	1	0	1
1	7	6	6	5	5	0	0
0	7	6	7	5	5	5	5
4	7	6	7	3	5	7	0
1	1	4	1	6	5	6	1
2	2	4	1	1	5	1	1
1	2	2	0	0	0	0	5

Dari Tabel 3 dapat dihitung probabilitas hubungan ketetangaan antara dua piksel pada jarak dan orientasi sudut tertentu. Kemudian akan diperoleh matriks kookurensi yang dapat dihitung ciri statistik yang merepresentasikan citra yang diamati. Karena matriks dari tabel 1 tersebut memiliki delapan aras keabuan, maka jumlah nilai piksel ketetangaan dan nilai piksel referensi pada area kerja matriks berjumlah 8.

**Table 3. Area Kerja Matriks**

	0	1	2	3	4	5	6	7
0	0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7
1	1,0	1,1	1,2	1,3	1,4	1,5	1,6	1,7
2	2,0	2,1	2,2	2,3	2,4	2,5	2,6	2,7
3	3,0	3,1	3,2	3,3	3,4	3,5	3,6	3,7
4	4,0	4,1	4,2	4,3	4,4	4,5	4,6	4,7
5	5,0	5,1	5,2	5,3	5,4	5,5	5,6	5,7
6	6,0	6,1	6,2	6,3	6,4	6,5	6,6	6,7
7	7,0	7,1	7,2	7,3	7,4	7,5	7,6	7,7

Langkah selanjutnya yaitu menghitung nilai matriks dengan mengisikan jumlah hubungan spasial sehingga akan menghasilkan nilai matriks seperti pada Tabel 4. Bagian ini memperlihatkan pencarian frekuensi kemunculan piksel. Cara pencarian dilakukan dengan mencari banyaknya piksel yang ada beserta tetangganya dengan jarak spasial 1 dan sudut 90 derajat dan akan diperoleh matriks kookurensi yang dapat dihitung ciri statistik yang merepresentasikan citra yang diamati.

**Table 4. Pembentukan Matriks Kookurensi**

	0	1	2	3	4	5	6	7
0	2	6	0	0	0	2	0	0
1	3	4	1	0	1	0	2	2
2	0	2	1	0	1	2	0	0
3	0	0	0	0	0	1	0	0

4	1	0	0	0	1	0	1	0
5	3	2	0	0	0	5	0	0
6	0	0	2	1	0	0	2	1
7	0	1	0	0	0	1	1	3

Langkah selanjutnya nilai dari hasil pertama GLCM dicari nilai transposnya seperti pada Tabel 5.

**Table 5. Matriks Transpose Hasil Perhitungan**

2	3	0	0	1	3	0	0
6	4	2	0	0	2	0	1
0	1	1	0	0	0	2	0
0	0	0	0	0	0	1	0
0	1	1	0	1	0	0	0
2	0	2	1	0	5	0	1
0	2	0	0	1	0	2	1
0	2	0	0	0	0	1	3

Hasil dari nilai transpose dijumlahkan dengan nilai hasil pertama GLCM dan akan menghasilkan nilai matriks yang belum ternormalisasi seperti pada Tabel 6.

**Table 6. Hasil Penjumlahan**

4	9	0	0	1	5	0	0
9	8	3	0	1	2	2	3
0	3	2	0	1	2	2	0
0	0	0	0	0	1	1	0
1	1	1	0	2	0	1	0
5	2	2	1	0	10	0	1
0	2	2	1	1	0	4	2
0	3	0	0	0	1	2	6

Matriks yang telah di jumlahkan selanjutnya harus dinormalisasi elemen-elemennya yang dinyatakan dengan probabilitas. Nilai elemen untuk masing-masing sel dibagi dengan jumlah seluruh elemen spasial seperti pada Tabel 7.

**Table 7. Hasil Normalisasi**

0,0364	0,0818	0,0000	0,0000	0,0091	0,0455	0,0000	0,0000
0,0818	0,0727	0,0273	0,0000	0,0091	0,0182	0,0182	0,0273
0,0000	0,0273	0,0182	0,0000	0,0091	0,0182	0,0182	0,0000
0,0000	0,0000	0,0000	0,0000	0,0000	0,0091	0,0091	0,0000
0,0091	0,0091	0,0091	0,0000	0,0182	0,0000	0,0091	0,0000
0,0455	0,0182	0,0182	0,0091	0,0000	0,0909	0,0000	0,0091
0,0000	0,0182	0,0182	0,0091	0,0091	0,0000	0,0364	0,0182
0,0000	0,0273	0,0000	0,0000	0,0000	0,0091	0,0182	0,0545

Setelah diperoleh matriks kookurensinya dapat dihitung ciri statistik orde-dua yang merepresentasikan citra kayu. Dalam matriks kookurensi, terdapat berbagai ciri tekstur yang dapat diperoleh dari suatu citra yang digunakan sebagai pembeda antara citra dengan kelas tertentu atau kelas lainnya. Fitur ciri yang digunakan antara lain kontras, korelasi, homogenitas, dan energi.

### 3.4 Gray Level Co-Occurrence Matrix

GLCM merupakan matriks berukuran  $L \times L$  ( $L$  menyatakan banyaknya tingkat keabuan) dengan elemen-elemen  $P(x_1, x_2)$  yang merupakan distribusi probabilitas bersama dari pasangan pixel dengan tingkat keabuan  $x_1$  yang beralokasi pada koordinat  $(j, k)$  dengan  $x_2$  yang beralokasi pada koordinat  $(m, n)$ . Koordinat pasangan pixel tersebut berjarak  $r$  dengan sudut  $\theta$ . Setelah matriks *co-occurrence* terbentuk, maka tiap elemen matriks  $p(i_1, i_2)$  perlu dinormalisasi dengan membagi tiap elemen dengan bilangan yang merupakan jumlah total dari pasangan piksel. Pengukuran nilai tekstur didasarkan pada persamaan Harralick yang didefinisikan sebagai berikut:

$$\begin{aligned}
 \text{Kontras} &= \sum_i \sum_j (i-j)^2 C(i,j) && \dots\dots\dots (1) \\
 \text{Korelasi} &= \sum_i \sum_j \frac{|i-j| \cdot C(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} && \dots\dots\dots (2) \\
 \text{Homogenitas} &= \sum_i \sum_j \frac{C(i,j)}{1+(i-j)} && \dots\dots\dots (3) \\
 \text{Energi} &= \sum_i \sum_j C^2(i,j) && \dots\dots\dots (4)
 \end{aligned}$$

**keterangan:**

- C( i,j ) : Co-Occurrence Matrices ternormalisasi
- $\mu_x$  : nilai rata-rata elemen kolom pada matriks Pd ( i,j )
- $\mu_y$  : nilai rata-rata elemen baris pada matriks Pd ( i,j )
- $\sigma_x$  : nilai standart deviasi elemen kolom pada matriks
- $\sigma_y$  : nilai standart deviasi elemen baris pada matriks

No	Proses	Keterangan
1	Kontras	Ukuran penyebaran elemen elemen matriks citra
2	Korelasi	Ukuran ketergantungan linear derajat keabuan citra
3	Homogenitas	Jarak distribusi elemen-elemen dalam GLCM
4	Energi	Ukuran sifat homogenitas citra

**Table 8. Fitur GLCM**

**3.5 Tahap Persiapan Preprocessing**

*Preprocessing* merupakan proses untuk merubah data yang belum siap digunakan menjadi data yang siap digunakan untuk klasifikasi. Maka dari itu dibutuhkan *preprocessing* untuk meningkatkan kualitas dari data sehingga proses selanjutnya dapat lebih efisien. Tahap yang harus di persiapkan antara lain :

No	Proses	Keterangan
1	Data input	Nilai input yang dihasilkan dari proses perhitungan GLCM
2	Jumlah <i>hidden layer</i>	Inisialisasi jumlah <i>hidden layer</i> yang akan digunakan
3	Jumlah <i>output layer</i>	Inisialisasi jumlah <i>output layer</i> yang akan digunakan
4	Inisialisasi parameter pendukung	Menentukan jumlah <i>learning rate, epoch, dan</i> algoritma pelatihan yang digunakan

**Table 9. Data Preprocessing**

**3.6 Tahap Pemodelan**

**3.6.1. Arsitektur Jaringan Syaraf Tiruan**

Jaringan syaraf tiruan merupakan generalisasi model matematis dari pemahaman manusia. Berbeda dengan metode lain, algoritma untuk JST beroperasi langsung dengan angka sehingga data yang tidak numerik harus diubah menjadi data numerik[12]. Jaringan syaraf tiruan menyelesaikan masalah melalui proses belajar dari contoh-contoh pelatihan yang diberikan. Jaringan akan menyesuaikan nilai bobotnya atas pola masukan dan sasaran yang disajikan tersebut. Tujuan penelitian ini bagaimana dengan metode jaringan syaraf tiruan backpropagation dapat mengklasifikasi-kan jenis kayu. Secara teori JST minimal memiliki 3 unit pengolah, diantaranya adalah :

1. *Input layer*  
Lapisan unit ini menyatakan nilai sebuah pola yang digunakan untuk masukan pada jaringan.
2. *Hidden layer*  
Lapisan ini merupakan lapisan penghubung antara *input layer* dan *output layer* dimana *output* yang dikeluarkan tidak secara langsung diamati. Pada kasus-kasus tertentu, pada jaringan memungkinkan memiliki hidden layer lebih dari satu[15]. Namun beberapa teori menyebutkan bahwa penggunaan *hidden neuron* yang terlalu besar akan memicu munculnya kondisi *overfitting*[14].
3. *Output layer*

Merupakan lapisan terakhir pada JST yang berfungsi untuk tempat keluaran. Pada beberapa penerapan, unit keluaran digunakan untuk merepresentasikan sebuah pola.

Awal dari proses ini akan pembentukan sebuah JST dengan parameter yang telah ditentukan oleh *user*. Parameter ini antara lain *learning rate* ( $\alpha$ ), *error target*, *maksimum epoch*, *fungsi training*, *fungsi aktivasi*, jumlah *hidden layer* dan jumlah *neuron* tiap-tiap *layer*. BPNN terdiri dari beberapa tahapan sebagai berikut:


1. Inisialisasi jumlah *input*, *hidden layer*, dan *output*.
2. Inisialisasi jumlah *learning rate*, *epoch* dan parameter *goal performance*
3. Masukkan data inputan ke jaringan dan hitung nilai keluaran pada tiap-tiap *node*.
4. Jumlah *hidden layer*
5. Fungsi pelatihan jaringan yang digunakan
6. Hitung akurasi prediksi

### 3.6.2 Faktor bobot dan Fungsi Aktivasi

Bobot merupakan suatu nilai yang mendefinisikan tingkat atau kepentingan hubungan antara suatu *node* dengan *node* yang lain. Semakin besar bobot suatu hubungan menandakan semakin pentingnya hubungan kedua *node* tersebut. Setiap *neuron* mempunyai keadaan *internal* yang disebut level aktivasi atau level aktivitas yang merupakan fungsi *input* yang diterima. Secara tipikal suatu *neuron* mengirimkan aktivitasnya ke beberapa *neuron* lain sebagai sinyal. Yang perlu diperhatikan adalah bahwa *neuron* hanya dapat mengirimkan satu sinyal sesaat, walaupun sinyal tersebut dapat dipancarkan ke beberapa *neuron* yang lain. Ada beberapa pilihan fungsi aktivasi yang digunakan dalam metode *backpropagation*, seperti fungsi *sigmoid biner*. Karakteristik yang harus dimiliki fungsi aktivasi tersebut adalah *kontinue*, *diferensiabel*, dan tidak menurun secara monoton. Fungsi aktivasi diharapkan dapat mendekati nilai-nilai maksimum dan minimum secara baik. Berikut ini adalah fungsi aktivasi yang sering digunakan yaitu fungsi *sigmoid biner* digunakan untuk jaringan syaraf yang dilatih dengan menggunakan metode *backpropagation*. Fungsi *sigmoid biner* memiliki nilai pada range 0 sampai 1 [19]. Karakteristik yang harus dimiliki fungsi aktivasi tersebut adalah kontinyu dan tidak menurun secara monoton. Dari hasil penelitian maka didapatkan bahwa penggunaan fungsi aktivasi sigmoid biner memiliki tingkat rata-rata akurasi yang lebih baik dari sigmoid bipolar. Rumus yang digunakan yaitu :

$$f1(x) = \frac{1}{1+e^{-x}} \quad (5)$$

Berikut ini gambaran fungsi sigmoid biner dengan range (0,1) :



Gambar 8. Fungsi Sigmoid Biner

### 3.6.3 Model Jaringan Syaraf Tiruan Backpropagation


Algoritma pelatihan yang digunakan pada Jaringan Syaraf Tiruan untuk memperbaiki bobot adalah algoritma *backpropagation*. *Backpropagation* merupakan algoritma pembelajaran yang biasanya digunakan oleh *perceptron* dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan *neuron-neuron* yang ada pada lapisan tersembunyinya. Algoritma *backpropagation* menggunakan *error output* untuk mengubah nilai-nilai bobotnya yang berada diantara lapisan *output* ke *hidden layer* kemudian bergerak mundur untuk memperbaiki bobot yang berada diantara *hidden layer* dan *input layer*. Tahap perambatan maju (*forward propagation*) harus dikerjakan terlebih dahulu untuk mendapatkan nilai *error* tersebut. Saat perambatan maju *neuron-neuron* diaktifkan dengan menggunakan fungsi aktivasi *sigmoid biner*. Selama proses pelatihan iterasi akan dihentikan apabila telah melebihi *maksimum epoch* atau nilai *error* yang telah ditentukan. Performansi jaringan & *error goal* dinyatakan dalam nilai MSE.

### 3.6.4 Penentuan Arsitektur Jaringan Syaraf Tiruan

Jaringan saraf tiruan diatas terdiri dari 4 lapisan untuk input, 2 lapisan pelatihan atau hidden layer serta 1 lapisan output. Variabel X1 sampai X4 merupakan data input. Variabel Z adalah variabel untuk pelatihan atau pembelajaran bagi jaringan ini. Terakhir variabel Y merupakan *output* yang akan dihasilkan. Pada *backpropagation* jika pelatihan yang dilakukan belum mencapai tujuan yang diinginkan maka *output* akan menjadi inputan kembali. Dan akan dilakukan terus-menerus sampai mencapai goal yang diinginkan. Dalam



pelatihan ini, simulasi dilakukan dengan menerapkan beberapa fungsi pelatihan. Fungsi yang akan digunakan adalah algoritma *Learning Rate Gradient Descent* dan *Levenberg Marquardt*. Sedangkan fungsi aktivasi yang digunakan adalah fungsi *aktivasi sigmoid biner* pada *layer input* dan *layer output*.



Gambar 9. Arsitektur JST Backpropagation

### 3.7 Proses Training Jaringan Syaraf Tiruan Backpropagation

Awal dari proses ini akan pembentukan sebuah JST dengan parameter yang telah ditentukan oleh user. Parameter ini antara lain learning rate ( $\alpha$ ), error target, maksimum epoch, fungsi training, fungsi aktivasi, jumlah hidden layer dan jumlah neuron tiap-tiap layer. BPNN terdiri dari beberapa tahapan sebagai berikut:

1. Inisialisasi jumlah input, *hidden layer*, *output* dan bias. Pada awal fase ini, dilakukan penjumlahan bobot pada *hidden layer* dengan menggunakan rumus :

$$Z_{net} = \sum_{n=1} W_{ij} X_{ij} \quad (6)$$

Dimana  $i$  merupakan neuron ke- $i$  ( $i=1,2,\dots,n$ ) pada lapisan input dan  $j$  merupakan neuron ke- $j$  ( $j=1,2,\dots,p$ ) pada hidden layer.  $x_{ij}$  merupakan nilai nput pada input neuron  $i$  ke hidden neuron  $j$ .  $w_{0j}$  merupakan bias pada lapisan input, sedangkan  $w_{ij}$  merupakan bobot pada input neuron  $i$  yang menuju ke hidden neuron  $j$ .

2. Setelah penjumlahan bobot pada hidden layer dilakukan, kemudian diterapkan fungsi aktivasi pada bobot tersebut menggunakan fungsi aktivasi Sigmoid. Hasil dari penerapan fungsi aktivasi ini menjadi nilai yang akan digunakan oleh neuron pada hidden layer untuk proses selanjutnya. Rumus yang digunakan pada tahap penerapan fungsi aktivasi ini adalah sebagai berikut :

$$Z_j = f(Z_{net}) \frac{1}{1+e^{-Z_{net}}} \quad (7)$$

Dimana  $e$  merupakan bilangan natural yang memiliki nilai sama dengan 2.718281828. Hasil perhitungan dari  $f(Z_{net})$  ini merupakan nilai aktivasi pada hidden neuron  $j$  untuk kemudian dikirimkan ke seluruh output neuron.

3. Tahap selanjutnya setelah didapatkan nilai numerik tiap neuron pada hidden layer adalah mengalirkan sinyal numerik tersebut ke layer selanjutnya, yakni output layer. Untuk melakukannya, tahapan yang digunakan identik dengan tahap ketika nilai pada input layer dialirkan pada hidden layer, yaitu menjumlahkan tiap bobot pada hidden layer dengan menggunakan rumus :

$$Y_{net_k} = V_{0k} \sum_{j=1}^k z_j v_{jk} \quad (8)$$

Nilai  $v_{0k}$  merupakan nilai bias pada hidden layer,  $z_j$  merupakan hasil nilai fungsi aktivasi yang keluar dari hidden layer dan  $v_{jk}$  merupakan bobot pada hidden neuron  $j$  menuju ke output neuron  $k$  ( $k=1,2,\dots,m$ ).

$$Y_k = f(Y_{net_k}) \frac{1}{1+e^{-Y_{net_k}}} \quad (8)$$

Sedangkan  $f(Y_{net_k})$  merupakan hasil fungsi aktivasi akibat penjumlahan bobot antara hidden neuron dan output neuron. Hasil fungsi aktivasi pada output neuron ini merupakan nilai keluaran aktual yang kemudian dihitung selisihnya dengan nilai target output-nya. Pada tiap iterasi, kemudian dihitung error keseluruhan dengan menggunakan rumus Mean Squared Error (MSE) [13]:

$$E = \frac{1}{N} \sum_{M=1}^N (T_k - Y_k)^2 \quad (10)$$

Pada rumus di atas,  $Y_k$  merupakan nilai output dari jaringan syaraf sedangkan  $T_k$  merupakan nilai target yang diinginkan untuk setiap keluaran dari  $N$  yang merupakan banyaknya dataset training. Jika nilai MSE yang dihasilkan masih belum sesuai dengan yang ditargetkan, maka proses akan dilanjutkan ke fase selanjutnya, yakni fase backpropagation dimana bobot-bobot pada jaringan diperbaiki untuk kemudian dialirkan kembali ke jaringan menggunakan proses feedforward. Proses ini akan berulang hingga nilai error mencapai threshold yang diharapkan atau sudah mencapai batas maksimal iterasi yang ditentukan.

4. kemudian hitung koreksi bobot (yang nantinya akan digunakan untuk memperbaiki  $W_{ij}$ )

$$\Delta W_{ij} = \alpha E Z_{net} \quad (11)$$

Hitung juga koreksi bias (yang nantinya akan digunakan untuk memperbaiki nilai  $w_{0k}$ ) :

$$\Delta W_{jk} = \alpha E \quad (12)$$

Kirimkan nilai ini ke unit-unit yang ada dilapisan bawahnya.

5. Hitung penjumlahan kesalahan di *hidden neuron*

$$\delta_{net} = E V_{jk} \quad (13)$$

Hitung faktor kesalahan di *hidden neuron*

$$\delta = (E \cdot Z_{net})(1 - Z_{net}) \quad (14)$$

Hitung suku perubahan bobot ke *hidden neuron*

$$\Delta w = \alpha \delta_{net} Z_j \quad (15)$$

Tiap unit output memperbaiki bias dan bobotnya.  $\Delta w_{ij}$  dan  $\Delta v_{jk}$  masing-masing merupakan besarnya perubahan yang akan ditambahkan pada bobot lama yang akan diperbaharui. Dimana  $\eta$  adalah laju pembelajaran,  $\delta$  adalah penjumlahan kesalahan di lapisan input dan hidden layer, serta antara hidden layer dan output layer.  $X_i$  merupakan nilai masukan yang berasal dari neuron  $i$  ke neuron  $j$  sedangkan  $Z_j$  merupakan hasil fungsi aktivasi yang keluar dari hidden layer. Setelah didapatkan  $\Delta w_{ij}$  dan  $\Delta v_{jk}$ , maka langkah selanjutnya adalah memperbaiki bobot lama menjadi bobot yang baru. Aturan perubahan bobot pada metode backpropagation dirumuskan sebagai berikut :

$$W_{jk}(\text{update}) = W_{jk} + \Delta W_{jk} \quad (16)$$

Tiap-tiap unit tersembunyi ( $z_j, j=1,2,3,\dots,p$ ) memperbaiki bias dan bobotnya ( $i=0,1,2,3,\dots,n$ )

$$V_{ij}(\text{update}) = V_{ij} + \Delta V_{ij} \quad (17)$$

$W_{ij}$  (baru) merupakan bobot baru antara input layer dan hidden layer yang akan dicari, sedangkan  $W_{ij}$  (lama) merupakan bobot lama yang diperbaharui.  $V_{jk}$  (baru) merupakan bobot baru antara hidden layer dan output layer yang akan dicari sedangkan  $V_{jk}$  (lama) merupakan bobot lama yang akan diperbaharui.

### 3.8 Tahap Evaluasi

Untuk melihat apakah JST yang sudah melalui proses pelatihan mampu mengenali pola data baru (*unseen data*), maka proses validasi dilakukan. Pada tahap ini, proses yang berjalan hanyalah proses *feedforward* saja. Seperti pada proses pembelajaran, hasil dari proses *feedforward* ini kemudian diukur keakuratannya untuk mengontrol apakah jaringan sudah dapat mengenali pola dengan baik. Pengukuran keakuratan hasil prediksi pada penelitian ini dilihat dari nilai MSE yang dihitung dengan menggunakan rumus (10). Jika hasil validasi menunjukkan nilai MSE mendekati nol, maka sistem yang dibangun dianggap sudah dapat diimplementasikan ke dalam sistem.

## 4. Evaluasi Dan Validasi


### 4.1 Skenario

Pengujian pada penelitian ini dijabarkan sebagai berikut:

Table 10. Skenario


No	Skenario	Tujuan
1	Pengujian nilai pixel distance dari berbagai sudut rotasi dan akurasi arah GLCM	Menguji pengenalan objek dengan pixel distance 1 sampai 4 dan menguji arah <i>gray level co-occurrence matrix</i> (GLCM) terhadap akurasi hasil klasifikasi dengan tujuan untuk mengetahui arah GLCM yang terbaik. Terdapat 4 arah GLCM yang digunakan pada pengujian ini yaitu, 0°, 45°, 90° dan 135°.
2	Pengujian metode pelatihan	Pengujian metode pelatihan <i>gradient descent</i> dan <i>levenberg-marquardt</i> untuk menghasilkan akurasi terbaik
3	Mengetahui Hasil Klasifikasi	Pengujian akurasi hasil klasifikasi dengan jaringan syaraf tiruan propagansi balik

#### 4.2 Hasil Pengujian dan Analisis Skenario 1 (Pengujian nilai pixel distance dari berbagai sudut rotasi):



Gambar 10. Pengujian Nilai Pksel

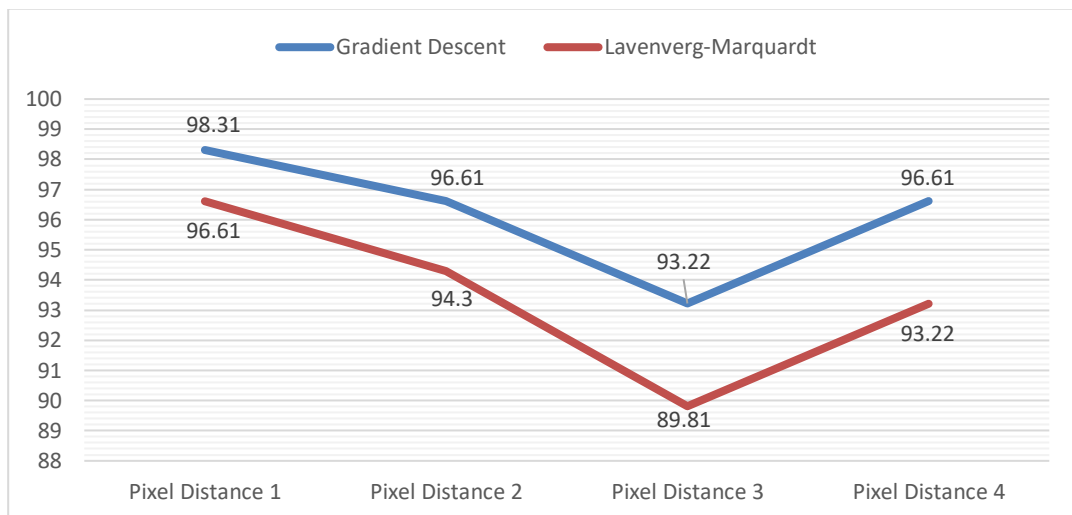
Berdasarkan Gambar 7 dapat dilihat bahwa nilai akurasi cenderung lebih tinggi pada *pixel distance* 1 dan 2 di semua arah, sedangkan nilai pada *pixel distance* 3 nilai akurasi cenderung turun atau rendah. Hal tersebut dikarenakan ketika *pixel distance* 1 dan 2 matriks awal dapat merepresentasikan nilai yang tepat sehingga dapat menghasilkan ekstraksi ciri yang baik sebesar 98,31%.



Gambar 11. Pengujian Nilai Pksel

Pada arah  $45^\circ$  dan  $135^\circ$  nilai akurasi cenderung sama, dikarenakan pada arah tersebut pasangan piksel yang dihasilkan kurang menggambarkan perbedaan nilai dari tekstur citra sehingga matriks GLCM dan ekstraksi ciri yang dihasilkan kurang baik. Hasil akurasi tertinggi sebesar 98,31% didapatkan pada arah  $0^\circ$ .

#### 4.3 Hasil Pengujian dan Analisis Skenario 2 (Pengujian metode pelatihan)



Gambar 12. Pengujian Metode Pelatihan

#### 4.4 Hasil Pengujian dan Analisis Skensrio 3 (Mengetahui hasil klasifikasi):

1. Membuat Jaringan Syaraf Tiruan Backpropagation dengan arsitektur 4-2-1 dan inisialisasi bobot awal secara acak. Pada pemrograman ini digunakan fungsi aktivasi sigmoid biner. Sedangkan fungsi pelatihan menggunakan metode *Gradien-Descent* dan metode *Levenberg-marquardt*
3. Metode *Gradient descent* memerlukan iterasi lebih banyak
4. Metode *Levenberg-marquardt* memiliki kecepatan yang lebih baik dalam proses pelatihan

## 5. Kesimpulan

Berdasarkan pengujian dan analisis yang telah dilakukan, maka kesimpulan yang dapat diambil adalah sebagai berikut :

1. Model jaringan yang digunakan dalam penelitian ini adalah model jaringan *backpropagation neural network*. Model jaringan ini dipilih karena kemampuannya dalam memahami peristiwa baru berdasarkan proses pelatihan yang dilakukan sebelumnya.
2. Proses training jaringan syaraf tiruan memerlukan waktu yang cukup lama untuk jumlah data yang banyak.
3. Jaringan syaraf tiruan mampu melakukan ekstraksi dari suatu pola data tertentu
4. karakteristik dari GLCM adalah mengetahui perbedaan nilai pada suatu piksel dengan piksel lainnya pada citra. Apabila nilai homogenitas kecil maka nilai kontrasnya besar. Ciri yang dihasilkan GLCM merepresentasikan nilai tekstur pada kayu. Sehingga nilai-nilai tersebut dapat dimanfaatkan untuk mengklasifikasikan jenis kelas kayu.
5. Dalam pengujian ini pixel distance 1 memiliki akurasi terbaik dengan sudut rotasi 0 derajat
6. Metode pelatihan Gradient Descent memiliki akurasi terbaik sebesar 98,3%
7. Nilai MSE yang digunakan adalah 0,01, nilai *epoch* sebanyak 1000 iterasi, nilai *Learning Rate*/laju pembelajaran adalah 0,1 menghasilkan akurasi terbaik pada pengujian ini.

### Daftar Pustaka

- [1] Sumarna, 2003, *etd.repository.ugm.ac.id*, 2014
- [2] Pullaperuma & Dharmaratne, Gray Level Co-Occurrence Matrix 2013.
- [3] A. W. SANJAYA, Deteksi Penyakit Kulit Menggunakan Analisis Fitur Warna Dan Tekstur Dengan Metode Color Moment, Gray Level Co-Occurrence Matrix, Dan Jaringan Saraf Tiruan Backpropagation, Bandung: Fakultas Teknik Elektro, IT Telkom, 2011.
- [4] R. A. Pramunendar, C. Supriyanto, Dwi Hermawan Novianto, Ignatius Ngesti Yuwono, G. F. Shidik, and P. N. Andono, "A classification method of coconut wood quality based on Gray Level Co-occurrence matrices," in 2013 International Conference on Robotics, Biomimetics, Intelligent Computational Systems, 2013, pp. 254–257.
- [5] Ajay KS, Tiwari S, VP Shukla. 2012. Klasifikasi Motif Batik Berbasis Kemiripan Ciri dengan Wavelet Transform dan Fuzzy Neural Network. Vol.3, No.1. Online.
- [6] R. A. Pramunendar, C. Supriyanto, Dwi Hermawan Novianto, Ignatius Ngesti Yuwono, G. F. Shidik, and P. N. Andono, "A classification method of coconut wood quality based on Gray Level Co-occurrence matrices," in 2013 International Conference on Robotics, Biomimetics, Intelligent Computational Systems, 2013, pp. 254–257.
- [7] Prasetyo, M. Khalid, R. Yusof, and F. Meriaudeau, "A Comparative Study of Feature Extraction Methods for Wood Texture Classification," 2010 Sixth Int. Conf. Signal-Image Technol. Internet Based Syst., pp. 23–29, 2010.
- [8] P. Mohanaiah, P. Sathyanarayana, and L. Gurukumar, "Image Texture Feature Extraction Using GLCM Approach," Int. J. Sci. Res. Publ., vol. 3, no. 5, pp. 1–5, 2013.
- [9] R. A. Pramunendar, C. Supriyanto, Dwi Hermawan Novianto, Ignatius Ngesti Yuwono, G. F. Shidik, and P. N. Andono, "A classification method of coconut wood quality based on Gray Level Co-occurrence matrices," in 2013 International Conference on Robotics, Biomimetics, Intelligent Computational Systems, 2013, pp. 254–257.
- [10] Fitri Damayanti, Husni, Elya Farida. 2010. Sistem perolehan citra berbasis isi Berdasarkan tekstur menggunakan metode Gray level co-occurrence matrix dan Euclidean distance. Vol 1, No 3. Fakultas Teknik. Universitas Trunojoyo Madura.
- [11] Prasetyo, M. Khalid, R. Yusof, and F. Meriaudeau, "A Comparative Study of Feature Extraction Methods for Wood Texture Classification," 2010 Sixth Int. Conf. Signal-Image Technol. Internet Based Syst., pp. 23–29, 2010.
- [12] Hermawan, 2006, Jaringan Syaraf Tiruan Teori dan Aplikasi, Penerbit Andi Yogyakarta
- [13] Kardan, A.A., Sadeghi, H., Ghidary, S.S., Sani, M.R.F. 2013. Prediction of Student Course Selection in Online Higher Education Institutes Using Neural Network, Computer & Education 65(2013), 1-11
- [14] Karsoliya, S., 2012. Approximating Number of Hidden Layer Neurons in Multiple Hidden Layer BPNN Architecture, International Journal of Engineering Trends and Technology Vol.3 Issue.6, 714-717
- [15] F. Pakaja and A. Naba, "Jaringan Syaraf Tiruan dan Certainty Factor," vol. 6, no. 1, pp. 23–28, 2015.
- [16] Heaton, J., 2008. Introduction to Neural Networks for C, Second Edition, Heaton Research, St Louis
- [17] Moucary, C.E., Khair, M., Zakhem, W., 2006, Improving Student Performance Using Data Clustering and Neural Networks in Foreign- Language Based Higher Education, The Research Bulletin of Jordan ACM Vol II(III), 27-34
- [18] Siang, J.J., 2009. Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan MATLAB, Penerbit Andi, Yogyakarta
- [19] Puspaningrum, D. (2006). Pengantar Jaringan Syaraf Tiruan. Yogyakarta : Andi Offset
- [20] Haralick, R.M., K. Shanmugan, and I. Dinstein, "Textural Features for Image Classification", IEEE Transactions on Systems, Man, and Cybernetics, Vol. SMC-3, 1973, pp. 610-621.
- [21] Haralick, R.M., and L.G. Shapiro. Computer and Robot Vision: Vol. 1, Addison-Wesley, 1992, p. 459.
- [22] Surya, R. A., Fadhil, A. & Yudhana, A., 2017. Ekstraksi Ciri Metode Gray Level Co- Occurrence Matrix (GLCM) dan Filter Gabor Untuk Klasifikasi Citra Batik Pekalongan. Jurnal Informatika: Jurnal Pengembangan IT, Volume 02.
- [23] Ferry Anggriawan Susanto, "Identifikasi Daging Sapi dan Daging Babi Menggunakan Fitur Ekstraksi Gray Level Co-occurrence Matrix dan k- Nearest Neighbor Classifier," Universitas Dian Nuswantoro, Semarang, Skripsi 2015.
- [24] Fausett, L. 1994. Fundamentals of Neural Networks (Architectures, Algorithms, and Applications). New Jersey: Prentice-Hall
- [25] Marzuki Khalid, Rubiyah Yusof, and Anis Salwa Mohd Khairudin, "Improved Tropical Wood Species Recognition System based on Multi-feature Extractor and Classifier," World Academy of Science, Engineering and Technology, 2011.

- [26] Ishak Taman et al., "Classification System for Wood Recognition Using K-Nearest Neighbor with Optimized Feature from Binary Gravitational Algorithm," International Conference Recent trends in Engineering & Technology, pp. 13-14, February 2014.