

DETEKSI ADANYA CACAT PADA KAYU MENGUNAKAN METODE LOCAL BINARY PATTERN

DETECTION OF THE EXISTENCE OF THE DEFECTS IN WOOD USING LOCAL BINARY PATTERN

Faisal Nur Achسانی¹, Ratri Dwi Atmaja², Rita Purnamasari³

¹Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

^{2,3}Fakultas Teknik Elektro, Universitas Telkom

¹faisalachsani@gmail.com, ²ratriidwiatmaja@telkomuniversity.ac.id, ³ritapurnamasari@telkomuniversity.ac.id

Abstrak

Penggunaan kayu sebagai bahan bangunan sampai sekarang ini masih tetap diminati banyak masyarakat meskipun banyak alternatif bahan lain yang dapat digunakan. Dalam industri pengolahan kayu di Indonesia sangat perlu adanya proses pemilahan kayu mentah yang nantinya akan diproses dalam tahap selanjutnya. Namun hingga sekarang proses pemilahan kayu mentah dilakukan dengan manual, dan dilakukan dengan menggunakan tenaga manusia, sehingga akan membutuhkan waktu yang cukup lama dan tidak efisien. Tugas akhir ini dibuat dengan tujuan untuk mensimulasikan suatu sistem yang mampu menganalisis ada tidaknya cacat pada kayu yang digunakan dalam proses pemilahan di industri pengolahan kayu. Dengan menggunakan metode *Local Binary Pattern* (LBP) untuk tahap awal ekstraksi cirinya. LBP didefinisikan sebagai perbandingan nilai biner piksel pada pusat citra dengan nilai piksel disekelilingnya. Hasil dari LBP ini akan diproses pada ekstraksi ciri statistik, sehingga menghasilkan vektor ciri yang dijadikan masukan pada klasifikasi citra dengan menggunakan metode *K-Nearest Neighbor* (KNN). Hasil dari simulasi yang dilakukan sistem dapat mendeteksi adanya cacat pada kayu dengan tingkat akurasi tertinggi adalah 89,4%, FAR sebesar 7,6% dan FRR sebesar 3%, dengan waktu komputasi rata-rata sistem sebesar 0,3069 detik.

Kata kunci : cacat kayu, LBP, ekstraksi ciri statistik, K-NN, FAR, FRR

Abstract

The using of wood as a building material is still high until now and keep demanded by society. In Indonesia, the wood processing industry really requires the selection process of raw wood. However, until now the selection process of raw wood is still done manually by human, so it requires quite long time and inefficient. This final project is created with the aim to simulate a system that is capable of analyzing the existence of defects in the wood used in the selecting and sorting process in the wood processing industry. By using the *Local Binary Pattern* (LBP) for the initial phase extraction characteristics. LBP is defined as the ratio of the binary pixel value at the center of the image with the value of the surrounding pixels. The results of this LBP will be processed on a statistical feature extraction, resulting feature vector is used as input in image classification using the *K-Nearest Neighbor*. The results of the simulation system can detect the existence of defects in wood with highest accuracy 89.4%, which FAR at 7.6% and FRR at 3%, with the average computation time for 0.3069 seconds.

Keywords : cacat kayu, LBP, statistics feature extraction, K-NN, FAR, FRR


1. Pendahuluan

Dalam industri pengolahan kayu di Indonesia, sangat perlu adanya proses pemilahan kayu mentah yang nantinya akan diproses dalam tahap selanjutnya. Karena dalam beberapa kondisi, kayu yang mempunyai kondisi buruk dan cacat tidak akan digunakan. Hingga sekarang, proses pemilahan kayu mentah dilakukan secara manual, dengan menggunakan tenaga manusia, sehingga membutuhkan waktu yang cukup lama dan tidak efisien.

Oleh karena penentuan dan pemilahan kayu berdasarkan kenampakan sisi kayu yang dilakukan di industri kayu masih bersifat subjektif dan tidak efisien, diperlukan sistem pendeteksian dengan maksud mempermudah proses produksi. Disini ini menjelaskan suatu sistem yang dirancang menggunakan metode untuk pendeteksian adanya cacat pada kayu dari kenampakan sisi kayu olahan industri, berbasis pengolahan citra digital.

Digunakan metode *Local Binary Pattern* (LBP) untuk transformasi sebagai tahap awal ekstraksi ciri dan menggunakan metode ekstraksi ciri statistik. Sistem ini mengolah citra kenampakan kayu yang memiliki gradasi warna tipis. Dengan metode LBP yang merupakan salah satu metode segmentasi warna, mengelompokkan citra kayu ke dalam cluster-cluster warna dan mempertegas gradasinya menjadi suatu ciri khusus.[3][5] Karakteristik

LBP merupakan ukuran intensitas relatif suatu piksel dengan intensitas piksel disekitarnya. Hasil dari LBP ini akan diproses pada ekstraksi ciri statistik, sehingga menghasilkan vektor ciri yang dijadikan masukan pada klasifikasi citra dengan menggunakan metode KNN.



Gambar 1 (a) cacat mata kayu (b) cacat retak (c) cacat lubang

2. Dasar Teori

2.1 Local Binary Pattern[3][5][8]

Operator LBP adalah salah satu analisis tekstur yang telah banyak digunakan dalam berbagai penerapan dan aplikasi. LBP telah terbukti diskriminatif dengan keuntungan utamanya, yaitu variasi untuk perubahan tingkat abu-abu monoton dan efisiensi komputasi, membuat LBP sangat cocok untuk tugas gambar menuntut analisis. Ide untuk menggunakan LBP untuk deskripsi tekstur didukung oleh komposisi pola mikro yang dapat dijelaskan oleh sebuah operator. *Local Binary Pattern* (LBP) didefinisikan sebagai ukuran tekstur *gray-scale*, berawal dari definisi umum tekstur di daerah sekitar[3][5].

Versi asli dari operasi LBP bekerja pada blok piksel 3x3 dari sebuah citra. Piksel-piksel di blok tersebut kemudian diberikan *threshold* oleh piksel tengah, lalu dikalikan kuadrat dua, dan kemudian dijumlahkan untuk mendapatkan label baru untuk piksel tengah. Karena sebuah ketetanggaan dari piksel terdiri dari delapan piksel, sejumlah $2^8=256$ label yang berbeda yang mungkin didapatkan bergantung kepada nilai keabuan relatif dari piksel tengah pada ketetanggaan piksel[5].

9	3	1
10	7	5
8	3	7

threshold		
1	0	0
1		0
1	0	1


bobot		
1	2	4
128		8
64	32	16

Pola = 11110001
 LBP = 1+32+64+128 =225

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p, \quad s(x) = \begin{cases} 1, & \text{if } x \geq 0 \\ 0, & \text{lainnya} \end{cases} \quad (1)$$

Rumus komputasi LBP[5]

Operator LBP memiliki label yang ditandai dengan P dan R. P mewakili jumlah pixel tetangga yang digunakan dalam komputasi sementara R adalah radius antara pixel titik pusat dan pixel tetangga.



Gambar 2 Contoh varian pola ketetanggaan LBP[8]

Dalam aplikasi analisis tekstur banyak diinginkan untuk memiliki fitur yang invarian atau kuat untuk rotasi gambar input. Sebagai LBP, pola P,R diperoleh dengan sirkuler sampel sekitar pixel pusat, rotasi gambar input memiliki dua efek: setiap lingkungan lokal diputar ke lokasi pixel lainnya, dan dalam masing-masing lingkungan, titik sampling padalingkaran yang mengelilingi titik pusat diputar ke orientasi yang berbeda[5].

2.2 Ekstraksi Ciri Statistik Orde Pertama[2]

Ekstraksi orde pertama merupakan metode pengambilan ciri yang didasarkan pada karakteristik histogram suatu citra. Histogram menunjukkan probabilitas kemunculan nilai derajat keabuan piksel pada suatu citra. Dari nilai-nilai pada histogram yang dihasilkan, dapat dihitung beberapa parameter ciri orde pertama, antara lain adalah *mean*, *skewness*, *variance*, *kurtosis* dan *entropy*. [2]

1. *Mean* (μ) yaitu parameter yang menunjukkan ukuran dispersi citra. dimana f_n merupakan nilai intensitas keabuan, dan $p(f_n)$ menunjukkan nilai histogramnya (probabilitas kemunculan intensitas tersebut).
2. *Variance* (σ^2) yaitu parameter yang menunjukkan variasi elemen pada histogram dari suatu citra.

3. *Skewness* (α_3) yaitu parameter yang menunjukkan tingkat kemencengan relatif kurva histogram.
4. *Kurtosis* (α_4) yaitu parameter yang menunjukkan tingkat keruncingan relatif kurva histogram.
5. *Entropy* (H) yaitu parameter yang menunjukkan ukuran ketidakaturan bentuk dari suatu citra.

$$\mu = \sum_n f_n p(f_n) \tag{2}$$

$$\sigma^2 = \sum_n (f_n - \mu)^2 p(f_n) \tag{3}$$

$$\alpha_3 = \frac{1}{\sigma^3} \cdot \sum_n (f_n - \mu)^3 p(f_n) \tag{4}$$

$$\alpha_4 = \frac{1}{\sigma^4} \sum_n (f_n - \mu)^4 p(f_n) - 3 \tag{5}$$


$$H = - \sum_n p(f_n) \cdot \log_2(p(f_n)) \tag{6}$$

2.3 Ekstraksi Ciri Orde Kedua[2]

Pada beberapa kasus, ekstraksi orde pertama tidak lagi dapat digunakan untuk mengenali perbedaan antar citra. Pada kasus seperti ini, dibutuhkan pengambilan ciri statistik orde dua atau disebut juga dengan *Gray Level Co-occurrence Matrix* (GLCM). Salah satu teknik 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 antara tersebut. Kookurensi berarti kejadian bersama, yaitu jumlah kejadian satu level nilai piksel bertetangga dengan satu level nilai piksel lain dalam jarak (d) dan orientasi sudut (θ) tertentu. Jarak dinyatakan dalam *pixel* dan orientasi dinyatakan dalam derajat. Orientasi dibentuk dalam empat arah sudut dengan interval sudut 45° , yaitu sudut $0^\circ, 45^\circ, 90^\circ,$ dan 135° .

Matriks kookurensi merupakan matriks bujursangkar dengan jumlah elemen sebanyak kuadrat jumlah level intensitas pixel pada citra. Setiap titik (p,q) pada matriks kookurensi berorientasi θ berisi peluang kejadian pixel bernilai p bertetangga dengan pixel bernilai q pada jarak d serta orientasi θ dan $(180-\theta)$. [6]



Gambar 3 (a) Contoh citra dengan 4 tingkat keabuan (b) GLCM pada jarak 1 dan 0°

Matriks kookurensi terbentuk setelah terbentuk matriks simetris. Dengan menambahkan transpose dari matriks sebelumnya maka matriks simetris dapat diperoleh.

$$\begin{bmatrix} 2 & 2 & 1 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 3 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix} + \begin{bmatrix} 2 & 0 & 0 & 0 \\ 2 & 2 & 0 & 0 \\ 1 & 0 & 3 & 0 \\ 0 & 0 & 1 & 1 \end{bmatrix} = \begin{bmatrix} 4 & 2 & 1 & 0 \\ 2 & 4 & 0 & 0 \\ 1 & 0 & 6 & 1 \\ 0 & 0 & 1 & 2 \end{bmatrix}$$

Gambar 4 Prosedur membuat matriks simetris[1]

Proses normalisasi dilakukan untuk menghapus ketergantungan pada ukuran dengan mengatur semua elemen dalam matriks sehingga total dari semua nilai elemen sama dengan 1.

$$\begin{bmatrix} \frac{4}{24} & \frac{2}{24} & \frac{1}{24} & \frac{0}{24} \\ \frac{2}{24} & \frac{4}{24} & \frac{0}{24} & \frac{0}{24} \\ \frac{1}{24} & \frac{0}{24} & \frac{6}{24} & \frac{1}{24} \\ \frac{0}{24} & \frac{0}{24} & \frac{1}{24} & \frac{2}{24} \end{bmatrix}$$

Gambar 5 Matriks ternormalisasi[1]

Setelah memperoleh matriks kookurensi, dapat menghitung ciri statistik orde dua yang merepresentasikan citra yang diamati. Yaitu[2] :

1. *Angular Second Moment* : Menunjukkan ukuran sifat homogenitas citra. Dimana $p(i,j)$ merupakan menyatakan nilai pada baris i dan kolom j pada matriks kookurensi.
2. *Contrast* : Menunjukkan ukuran penyebaran (momen inersia) elemen-elemen matriks citra. Jika letaknya jauh dari diagonal utama, nilai kekontrasan besar. Secara visual, nilai kekontrasan adalah ukuran variasi antar derajat keabuan suatu daerah citra.
3. *Correlation* : Menunjukkan ukuran ketergantungan linear derajat keabuan citra sehingga dapat memberikan petunjuk adanya struktur linear dalam citra.

4. *Variance* : Menunjukkan variasi elemen-elemen matriks kookurensi. Citra dengan transisi derajat keabuan kecil akan memiliki variansi yang kecil pula.
5. *Inverse Different Moment* : Menunjukkan kehomogenan citra yang berderajat keabuan sejenis. Citra homogen akan memiliki harga IDM yang besar
6. *Entropy* : Menunjukkan ukuran ketidakteraturan bentuk. Harga ENT besar untuk citra dengan transisi derajat keabuan merata dan bernilai kecil jika struktur citra tidak teratur (bervariasi).

$$ASM = \sum_i \sum_j \{p(i,j)\}^2 \quad (7)$$

$$CON = \sum_k k^2 [\sum_i \sum_j p(i,j)] \quad (8)$$

$k=|i-j|$

$$COR = \frac{\sum_i \sum_j (ij) \cdot p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (9)$$

$$VAR = \sum_i \sum_j (i - \mu_x)(j - \mu_y) p(i,j) \quad (10)$$

$$IDM = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i,j) \quad (11)$$

$$ENT = \sum_i \sum_j p(i,j) \cdot \log_2 p(i,j) \quad (12)$$

2.4 K-Nearest Neighbor (KNN) [4][7][9]

KNN adalah metode yang digunakan untuk mengklasifikasikan suatu data. Pada data latih biasanya diambil lebih dari satu tetangga terdekat dengan data uji kemudian akan digunakan algoritma ini untuk ditentukan kelasnya[7]. Jadi klasifikasi *k-NN* mempunyai dua langkah, yaitu menentukan jarak tetangga terdekat dari data tersebut lalu menentukan kelas dari masing - masing tetangga terdekat tersebut.


Pada penelitian ini digunakan jenis jarak KNN euclidean distance, yaitu[22][9]:
Euclidean Distance :

$$L(X,Y) = \sqrt{\sum_{i=1}^d (X_i - Y_i)^2} \quad (13)$$

3. Pembahasan

3.1 Akuisisi Citra

Proses akuisisi menggunakan objek gambar dari sisi penampang kayu olahan industri yang terlihat kenampakan permukaannya untuk kemudian dicitrakan menggunakan *webcam* dengan bantuan pencahayaan yang sama dan merata menggunakan LED (*Light Emitting Diode*). Berikut contoh hasil akuisisi citra :



Gambar 6 Citra penampang kayu hasil proses akuisisi.

Dalam tugas akhir ini, digunakan citra kayu sebanyak 500 gambar untuk data uji, dimana 410 adalah citra kayu tanpa cacat, dan 90 adalah citra kayu cacat. Setiap gambar memiliki ukuran sebesar 800 x 1280 piksel.

3.2 Pre-processing

3.2.1 Cropping

Proses *cropping* digunakan untuk mengambil bagian citra yang penting saja, menghapus bagian yang tidak digunakan untuk tahap selanjutnya. Selain itu teknik *cropping* dalam tugas akhir ini digunakan untuk memotong citra dan mengambil bagian sisi penampang kayu pada citra.

3.2.2 Resizing

Proses *resizing* digunakan untuk perubahan ukuran pada citra yang diperoleh dikarenakan citra hasil *cropping* memiliki ukuran yang bervariasi. Untuk keseragaman diperlukan ukuran data yang seragam dari data masukan dengan ukuran *resize* 800x400.

3.2.3 Median Filtering

Filter median digunakan untuk menghilangkan *outliers*, yaitu nilai piksel ekstrim. Filter median mengatur nilai piksel dalam satu tetangga dan memilih nilai tengah atau median sebagai hasilnya, untuk menggantikan nilai piksel acuan tersebut. Pada tugas akhir ini digunakan median filter dengan percobaan pola jumlah tetangga 3x3, 5x5 dan 7x7.


3.2.4 Thresholding

Proses *thresholding* digunakan untuk men-*threshold* bagian piksel citra kayu yang terlihat signifikan paling berbeda dari bagian lainnya pada gambar. *Thresholding* dilakukan pada setiap *layer* (RGB) pada citra. Piksel yang memiliki derajat keabuan lebih kecil dari *threshold* akan diberikan nilai 0 (hitam). Sedangkan piksel yang memiliki derajat keabuan lebih besar dari *threshold* akan diubah menjadi 255 (putih). Sesuai formula :

$$BW(x,y) = \begin{cases} 0, & f(x,y) < T \\ 255, & f(x,y) \geq T \end{cases} \quad (14)$$

$$\text{dimana, } T = \frac{\min(f(x,y)) + \max(f(x,y))}{2} \quad (15)$$

Berikut merupakan contoh hasil *thresholding* pada citra kayu :



Gambar 7 Citra penampang kayu hasil proses *thresholding*.

3.2.5 Grayscale

Tahap ini berfungsi mentransformasi citra dari RGB (3 layer) menjadi grayscale (1 layer), sesuai formula :

$$\text{Grayscale} = (0.299R + 0.587G + 0.114B) \quad (16)$$

3.3 Ekstraksi Ciri

3.3.1 Transformasi Local Binary Pattern

LBP yang digunakan pola ketetanggaan sirkular pada LBP : [8,1], dan [4,1]. Pengaruh parameter proses ekstraksi ciri statistik, yaitu penggunaan ekstraksi ciri statistik orde pertama (menggunakan histogram citra hasil LBP) dan ekstraksi ciri statistik orde kedua, GLCM (*Gray Level Co-ocurrence Matrix*).

3.3.2 Ekstraksi Ciri Statistik

3.3.2.1 Ekstraksi Ciri Orde Pertama

Ekstraksi ciri orde pertama adalah metode pengambilan ciri yang didasarkan karakteristik histogram citra hasil transformasi LBP. Dari beberapa nilai pada histogram yang dihasilkan, dapat dihitung beberapa parameter ciri orde pertama, yaitu *mean*, *skewness*, *variance*, *kurtosis*, dan *entropy*, menggunakan persamaan (2-6).

3.3.2.2 Ekstraksi Ciri Orde Kedua

Pada tugas akhir ini akan dibentuk matriks kookurensi dengan percobaan jarak $d=1$ piksel dengan sudut orientasi $\theta = 0^{\circ}, 45^{\circ}, 90^{\circ}, 135^{\circ}$ dan hasil rata-rata dari setiap sudut. Setelah mendapatkan matrik kookurensi ternormalisasi, dihitung parameter ekstraksi ciri analisis teksturnya yaitu *Angular Second Moment, Contrast, Correlation, Variance, Inverse Different Moment, Entropy* dan *Dissimilarity*, menggunakan persamaan (7-12).

3.4 Klasifikasi KNN

Dalam tugas akhir ini digunakan metode klasifikasi menggunakan KNN dengan jenis jarak *Euclidean Distance*. Simulasi yang dilakukan pada nilai k (jumlah tetangga) adalah 1, 3, 5, 7 dan 9. Dipilihnya nilai k yang ganjil agar mengurangi kesalahan algoritma jika peluang kemiripannya sama.

3.5 Perhitungan Performansi Sistem

Perhitungan performansi sistem menggunakan False Acceptance Rate (FAR), False Rejection Rate (FRR), dan akurasi sistem. FAR berguna untuk melihat sejauh mana sistem melakukan kesalahan dalam menerima masukan, dimana citra kayu yang seharusnya terdeteksi normal namun terdeteksi cacat oleh sistem. Sedangkan FRR menunjukkan sistem melakukan kesalahan dalam menolak masukan, dimana citra kayu yang seharusnya terdeteksi cacat namun terdeteksi normal oleh sistem. Secara sistematis perhitungan performansi sistem dapat dituliskan sebagai berikut:

$$FAR = \frac{\text{Jumlah data kayu normal terdeteksi cacat}}{\text{Jumlah data uji keseluruhan}} \times 100\% \quad (17)$$

$$FRR = \frac{\text{Jumlah data kayu cacat terdeteksi normal}}{\text{Jumlah data uji keseluruhan}} \times 100\% \quad (18)$$

$$\text{akurasi} = \frac{\text{Jumlah data benar}}{\text{Jumlah data keseluruhan}} \times 100\% \quad (19)$$

3.6 Hasil Pengujian Sistem dan Analisis

Hasil simulasi dapat dilihat pada gambar berikut :

Tabel 1 Perbandingan akurasi pengaruh filter median

Koefisien Filter Median	Kayu Normal Terdeteksi Normal	Kayu Cacat Terdeteksi Cacat	FAR	FRR	Akurasi
tanpa median filter	330	16	16%	14,8%	69,2%
3 x 3	336	19	14,8%	14,2%	71 %
5 x 5	335	17	15%	14,6%	70,4%
7 x 7	321	20	17,8%	14%	68,2%

Tabel 2 Perbandingan akurasi menggunakan *thresholding* dan tanpa *thresholding*

	Kayu Normal Terdeteksi Normal	Kayu Cacat Terdeteksi Cacat	FAR	FRR	Akurasi
menggunakan <i>thresholding</i>	356	36	10,8%	10,8%	78,4%
Tanpa <i>thresholding</i>	336	19	14,8%	14,2%	71%

Tabel 3 Perbandingan akurasi penggunaan perbedaan jumlah data latih

Jumlah Data	Data Latih	Data Latih	Kayu Normal Terdeteksi	Kayu Cacat Terdeteksi	FAR	FRR	Akurasi
-------------	------------	------------	------------------------	-----------------------	-----	-----	---------

Latih	Normal	Cacat	Normal	Cacat			
500	410	90	356	36	10,8%	10,8%	78,4%
180	90	90	320	78	18%	2,4%	79,6%

Tabel 4 Perbandingan akurasi pengaruh pola ketetangaan LBP dan ekstraksi ciri statistik

Pola Ketetangaan LBP	Ekstraksi Ciri Statistik	Kayu Normal Terdeteksi Normal	Kayu Cacat Terdeteksi Cacat	FAR	FRR	Akurasi
[4,1]	Orde 1	320	78	18%	2,4%	79,6%
	Orde 2	268	76	28,4%	2,8%	68,8%
[8,1]	Orde 1	300	79	22%	2,2%	75,8%
	Orde 2	293	79	23,4%	2,2%	74,4%

Tabel 5 Perbandingan akurasi pengaruh nilai k dengan jarak *euclidean* pada klasifikasi KNN

Nilai k	Kayu Normal Terdeteksi Normal	Kayu Cacat Terdeteksi Cacat	FAR	FRR	Akurasi
1	320	78	18%	2,4%	79,6%
3	343	77	13,4%	2,6%	84%
5	362	76	9,6%	2,8%	87,6%
7	370	76	8%	2,8%	89,2%
9	372	75	7,6%	3%	89,4%

4. Kesimpulan

Berdasarkan hasil percobaan dan analisis data pada sistem deteksi adanya cacat pada kayu berdasarkan pengolahan citra digital penampang kayu ditinjau dari tekstur dengan menggunakan transformasi *Local Binary Pattern* dan ekstraksi ciri statistik dan metode klasifikasi *K-Nearest Neighbor* maka dapat ditarik kesimpulan sebagai berikut :

1. Sistem yang dirancang dengan metode LBP dan ekstraksi ciri statistik orde pertama dan orde kedua, serta metode klasifikasi *KNN* dapat digunakan untuk mendeteksi adanya cacat pada kayu dengan tingkat akurasi tertinggi adalah 89,4%, dengan FAR sebesar 7,6% dan FRR sebesar 3%, dimana waktu komputasi rata-rata sistem 0,3069 detik.
2. Pada *preprocessing* tahap *median filtering* dengan koefisien 3 dan penggunaan tahap *thresholding* terbukti dapat meningkatkan akurasi sistem.
3. Jumlah data latih yang lebih seimbang menunjukkan tingkat akurasi yang lebih baik. Karena penggunaan jumlah data latih yang tidak seimbang antar kelasnya, membuat probabilitas perolehan *voting* pada klasifikasi *KNN* lebih banyak dimenangkan oleh kelas yang memiliki jumlah data latih lebih banyak.
4. Pola ketetangaan LBP [4,1] menghasilkan akurasi yang lebih baik baik daripada pola ketetangaan [8,1], begitu juga dengan ekstraksi ciri statistik orde pertama menghasilkan akurasi yang lebih tinggi daripada ekstraksi ciri statistik orde kedua (GLCM).
5. Metode klasifikasi *K-Nearest Neighbor* menghasilkan akurasi yang diharapkan pada sistem deteksi adanya cacat pada kayu. Terbukti pada saat nilai $k = 9$ dan menggunakan jenis ketetangaan *Cityblock Distance* dapat menghasilkan akurasi tertinggi. Sehingga secara analisis pola ciri latih dalam satu kelas tidak seragam sehingga saat dilakukan voting terhadap nilai k yang lebih besar akurasi akan menurun dikarenakan muncul kelas lainnya yang tidak seharusnya ada pada proses voting yang menjadi hasil kelas dari proses akhir klasifikasi *KNN*.

DAFTAR PUSTAKA

- [1] Kadir, Nugroho, L.E., Susanto, A., dan Santosa, P.I., 2011. *Neural Network Application on Foliage Plant Identification, International Journal of Computer Application (0975-8887)*, Vol.29. No.9, 15-22.
- [2] Modul 6 Analisis Teksstur & ekstraksi ciri. Available online at : <http://biomed.ee.itb.ac.id/courses/PengolahanCitra/2011/praktikum/Modul%205%20-%20EL3008.zip>, terakhir diakses tanggal 10 Januari 2014.
- [3] M. Heikkilä, M. Pietikäinen, C. Schmid, "Description of interest regions with local binary patterns," *Pattern Recognition*, vol. 42, no. 3, pp. 425-436, 2009.
- [4] Padraig. Cunningham, and Sarah Jane Delany, "k-Nearest Neighbor Classifier," Technical Report UCD-CSI, vol. 4, pp. 1-2, 2007.
- [5] Pietikäinen, M, Hadid, et al, *Computer Vision Using Local Binary Patterns*, London: Springer, 2010.
- [6] Rinaldi. Munir, *Pengolahan Citra Digital Menggunakan Pendekatan Algoritmik*, Bandung : Informatika. 2005
- [7] S. Aksoy, "Non Bayesian Classifier," *k-Nearest Neighbor Classifier and Distance Functions*. Ankara: Bilkent University., vol. I, pp. 5-6, 2008.
- [8] S. Liao, M. W. K. Law, and A. C. S. Chung, "Dominant local binary patterns for texture classification," *IEEE Trans. on Image Processing*, vol. 18, no. 5, pp. 1107-1118, 2009.
- [9] W. Hidayat, *Penerapan K-Nearest Neighbor Untuk Klasifikasi Gambar Landscape Berdasarkan Fitur Warna dan Teksstur*, Bandung: Pliteknik Telkom Bandung, 2009.