

KLASIFIKASI JENIS KAYU MENGGUNAKAN *BACK-PROPAGATION NEURAL NETWORK* BERDASARKAN *FITUR GRAY LEVEL CO-OCCURRENCE MATRIX*

R.A. Pramunendar¹, D.P. Prabowo², D. Pergiwati³ dan K. Latifa⁴
^{1,2,3} *Fakultas Ilmu Komputer, Universitas Dian Nuswantoro Semarang*

⁴ *Fakultas Teknik, Universitas PGRI Semarang*

ricardus.anggi@dsn.dinus.ac.id¹, dwi.puji.prabowo@ dsn.dinus.ac.id², pergiwati7@gmail.com³,
latifa.upgris@gmail.com⁴

Abstrak

Terdapat berbagai macam jenis kayu yang tumbuh dengan subur di Indonesia. Manfaat dari berbagai jenis kayu tersebut digunakan sebagai bahan baku pembuatan mebel. Melimpahnya jenis kayu di Indonesia tidak diikuti dengan pemanfaatan yang merata. Hal ini disebabkan oleh rendahnya pemahaman kualitas setiap jenis kayu. Pemanfaatan teknologi komputasi diharapkan dapat membantu perkembangan dalam sektor industri kayu, sehingga penggunaan kayu sebagai bahan baku dapat secara merata. Dalam penelitian ini digunakan empat jenis kayu yakni, jati, sengon, mahoni dan mindi sebagai dataset yang akan diklasifikasi dengan metode klasifikasi *Back-Propagation Neural Network* dan fitur *Gray Level Co-Occurrence Matrix*. Hasil perbandingan antara setiap parameter disajikan dan hasil terbaik menunjukkan nilai akurasi yang sangat baik yaitu dengan nilai rata-rata akurasi 96.13%. Output dari penelitian ini menghasilkan klasifikasi jenis kayu menggunakan metode BPNN dengan nilai akurasi yang baik.

Kata Kunci: Klasifikasi Kayu, *Back-Propagation Neural Network*, dan *Gray Level Co-Occurrence Matrix*

I. PENDAHULUAN

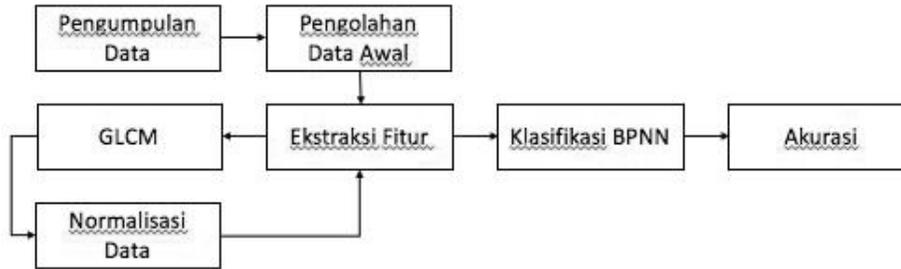
Kayu merupakan salah satu kekayaan hasil hutan yang memiliki peran besar dalam dunia industri baik industri kecil lingkup rumah tangga sampai industri besar dalam lingkup perdagangan dunia. Kayu memiliki banyak kegunaan dalam lingkungan di kehidupan sehari-hari mulai dari membuat rumah, mebel hingga kerajinan ukir dan barang antik. Beberapa negara Asia Tenggara khususnya di Indonesia menjadi penghasil utama dari ekspor produk yang terbuat dari kayu [1]. Jenis kayu yang umumnya dicirikan oleh ukuran, warna, serat dan juga corak dari kayu itu sendiri. Pengenalan atau identifikasi jenis kayu umumnya masih dilakukan secara visual berdasarkan ciri tersebut. Hal ini membutuhkan waktu yang cukup lama dan harus dilakukan oleh seorang yang sudah profesional dalam bidang dunia kayu [2], [3]. Sering terjadi kesalahan identifikasi kayu oleh petugas karena terbatasnya pengetahuan dan pengalaman sehingga waktu yang dibutuhkan untuk identifikasi lebih lama juga menambah biaya operasional [2], [3]. Banyaknya jenis kayu yang ada membuat proses pengenalan dan identifikasi jenis kayu secara manual membutuhkan waktu cukup lama karena perlu dilakukan berulang-ulang dan terus-menerus. Sehingga pada penelitian ini menggunakan salah satu algoritma klasifikasi *Back-Propagation Neural Network (BPNN)* yang berdasarkan fitur tekstur *Gray Level Co-Occurrence Matrix (GLCM)* untuk mencari parameter terbaik dalam mendapatkan akurasi pada proses identifikasi kayu.

Algoritma BPNN telah sukses diterapkan dalam beberapa penelitian. Seperti pada penelitian Zhou Dong [4], metode *neural network (NN)* digunakan untuk mendeteksi kuantitatif kerusakan kayu dalam mempengaruhi keandalan dan keamanan kayu untuk rekayasa konstruksi kayu. Hasilnya dapat dibuktikan dalam percobaan bahwa kerusakan dari kayu dapat dikenali dengan NN. Menurut Singh dkk [5] BPNN dan Haar Wavelet Transform memberi hasil diskriminasi klasifikasi citra yang lebih baik dan meningkatkan akurasi dari klasifikasi. Yuwono dkk [3] mengungkapkan metode klasifikasi Learning Vector Quantization Neural Network (LVQ-NN) dengan fitur berbasis biner mampu menghasilkan hasil akurasi yang cukup untuk proses identifikasi kualitas kayu kelapa. Namun oleh Pramunendar [2] membandingkan BPNN dan metode *Support Vector Machine (SVM)* berdasarkan fitur GLCM. Hasil yang diperoleh adalah metode BPNN mampu bekerja lebih baik dari pada algoritma SVM pada dataset kayu kelapa. Berdasarkan hasil yang diperoleh dari beberapa penelitian tersebut, fitur GLCM mampu menggambarkan ciri sesuai dengan gambar sesungguhnya dibanding dengan beberapa fitur yang lain [6]. Sehingga pada penelitian digunakan

metode BPNN dipilih sebagai algoritma yang bertugas untuk proses klasifikasi jenis kayu dan *GLCM* sebagai kombinasi dari algoritma yang berfungsi untuk ekstraksi fitur. BPNN membentuk sebuah pola yang di dapatkan dari pelatihan pengenalan pola dari masing-masing jenis kayu. Dan pola tersebut dijadikan pedoman dalam melakukan testing pada dataset baru. Sehingga diketahui berdasar pola apakah jenis kayu itu termasuk dalam salah satu jenis kayu yang diteliti.

II. METODE PENELITIAN

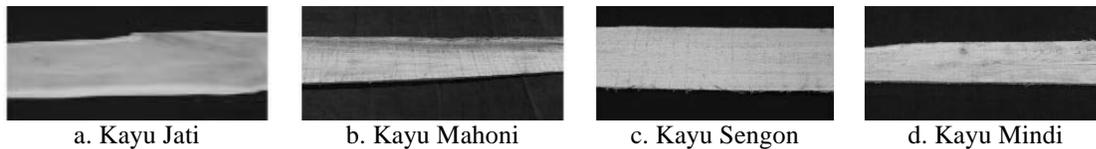
Proses pelaksanaan pada penelitian dilakukan secara experimental, dimana terdapat beberapa variabel yang saling mempengaruhi yaitu parameter BPNN dan fitur GLCM mempengaruhi hasil akurasi. Tahapan penyelesaian pada penelitian ini dijabarkan berdasarkan gambar berikut:



Gambar 6 Proses Pengenalan Kayu

2.1 Pengumpulan Data

Penelitian ini menggunakan empat (4) jenis kayu yaitu kayu jati, mahoni, mindi, dan sengon. Data tersebut diambil dari CV Majawana dan bekerjasama dengan Pendidikan Industri Kayu (PIKA) Semarang. Data merupakan data primer dengan total 400 data dari 4 jenis kayu, sehingga 1 jenis kayu terdapat 100 data gambar.



Gambar 7 Jenis Kayu

2.2 Pengolahan Data Awal

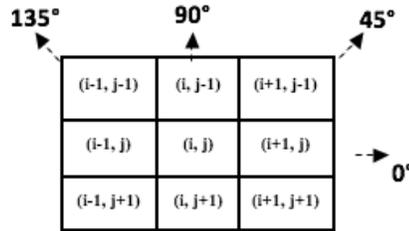
Citra asli yang telah dikumpulkan dilakukan dihilangkan background data dengan cara memberikan nilai 0 untuk background. Fitur GLCM yang digunakan pada penelitian ini tidak menuntut untuk menggunakan data dengan ukuran yang sama. Sehingga ukuran pada data tidak dilakukan perubahan bentuk. Proses pengolahan data lainnya berupa perubahan warna berupa grayscale, dan memisah layer warna R, warna G, dan warna B.

2.3 Ekstraksi Fitur

Kegiatan analisis tekstur tergantung pada karakteristik fitur tekstur yang diamati. Fitur tekstur yang berbeda memiliki karakteristik dan pendekatan berbeda. Tekstur kayu memiliki variasi yang beraneka macam tergantung jenisnya, dan GLCM mampu menggambarkan variasi tekstur yang dimiliki kayu [2], [6], [7].

2.3.1 GLCM

GLCM digunakan untuk ekstraksi fitur dari tekstur gambar daun cengkeh. Merupakan suatu matriks kookurensi yang merepresentasikan hubungan ketetanggaan antar piksel dalam citra pada berbagai arah orientasi dan jarak spasial [6], [7]. Terdapat 4 arah komputasi dalam GLCM, yaitu $\delta=0^\circ$, $\delta=45^\circ$, $\delta=90^\circ$, $\delta=135^\circ$.



Gambar 8 Sudut Matrik Kookurensi

Ada 5 fitur yang sering digunakan dari GLCM [2], [7] yaitu :

1. Angular Second Moment (ASM), akan bernilai tinggi jika nilai piksel pada gambar yang homogen tinggi.

$$ASM = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{P(i, j)\}^2 \dots \dots \dots (2.1)$$

G = jumlah intensitas warna yang digunakan.

2. Kontras adalah perbedaan intensitas antara piksel satu dan piksel yang berdekatan. Akan bernilai nol untuk gambar yang konstan.

$$Kontras = \sum_{n=0}^{G-1} n^2 \left\{ \sum_{i=0}^G \sum_{j=0}^G P(i, j) \right\}, |i - j| = n \dots \dots \dots (2.2)$$

3. Korelasi adalah ketergantungan linier antara piksel pada posisi tertentu terhadap piksel lain. Nilai yang lebih tinggi diperoleh pada daerah gray-level yang sama.

$$Korelasi = \frac{\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i, j)(P(i, j) - \mu_i' \mu_j')}{\sigma_i' \sigma_j'} \dots \dots \dots (2.3)$$

Dengan =

$$P_x(i) = \sum_{j=0}^{G-1} P(i, j) \dots \dots \dots (2.4)$$

$$P_y(j) = \sum_{i=0}^{G-1} P(i, j) \dots \dots \dots (2.5)$$

$$\mu_i' = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} i * P(i, j) \dots \dots \dots (2.6)$$

$$\mu_j' = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} j * P(i, j) \dots \dots \dots (2.7)$$

$$\sigma_i' = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j)(i - \mu_i')^2 \dots \dots \dots (2.8)$$

$$\sigma_j' = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} P(i, j)(j - \mu_j')^2 \dots \dots \dots (2.9)$$

4. IDM / Homogeneity mengukur homogenitas lokal gambar.

$$IDM = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{1}{1 + (i - j)^2} P(i, j) \dots \dots \dots (2.10)$$

5. Entropi semakin tidak seragam piksel-pikselnya maka entropinya akan semakin kecil, semakin besar nilai entropinya maka gambar tersebut semakin seragam.

$$\text{Entropi} = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (P(i, j) \times \text{Log}(P(i, j)) \dots \dots \dots (2.12)$$

Pada penelitian ini menggunakan 5 fitur yang dihasilkan oleh GLCM, diterapkan pada 4 sudut yaitu sudut 0°, 45°, 90°, 135° sehingga 1 gambar menghasilkan 20 fitur. Namun pada penelitian ini, inputan gambar terdiri dari 4 warna, yaitu, warna grayscale, layer R pada RGB, layer G pada RGB, dan layer B pada RGB. Sehingga pada penelitian ini menggunakan 80 fitur hasil kombinasi GLCM.

2.3.2 Normalisasi

Hasil yang didapatkan dari fitur GLCM sangat bervariasi, oleh sebab itu dilakukan normalisasi data. Normalisasi data digunakan untuk mengelompokkan data ke dalam skala atau jangkauan tertentu sehingga mempermudah dalam mengolah data. Normalisasi data pada penelitian ini menggunakan normalisasi data dalam jangkauan [0,1].

2.4 Klasifikasi BPNN

Back-Propagation Neural Network merupakan algoritma jaringan syaraf tiruan yang sebagian besar digunakan untuk pengolahan citra. BPNN digunakan untuk kompresi atau dekompresi citra. BPNN memiliki waktu yang sedikit lama dalam proses pelatihan namun memiliki tingkat akurasi yang sangat baik [2]. Dalam penelitian ini BPNN bertindak untuk proses klasifikasi. Klasifikasi oleh BPNN dilakukan dengan memberikan pelatihan secara berulang-ulang dari dataset jenis-jenis kayu sehingga terbentuk sebuah pola yang akan dijadikan sebagai dasar klasifikasi kayu. Setelah berhasil mengidentifikasi pola yang terbentuk, dilakukan proses testing pada BPNN. Hasil output dari serangkaian metode di atas adalah identifikasi jenis kayu apakah kayu jati, mahoni, sengon ataupun mindi. Pada penelitian ini melakukan pengujian terhadap berbagai parameter BPNN seperti *momentum*, *learning rate*, dan *training cycle*.

2.5 Evaluasi dan Validasi

Penelitian ini menggunakan *estimator cross-validation* k-fold. Oleh karena itu, menggunakan sampel data yang sama pada tahap pelatihan dan pengujian. Kami menguji penggunaan *cross-validation* dari 2 hingga 10. Sehingga untuk melatih dan menguji hasil klasifikasi dilakukan percobaan 2 hingga 10 kali dan mendapatkan rata-rata hasilnya. Dataset dibagi menjadi berdasarkan ukuran *cross-validation*, jika 10 yang digunakan maka akan membagi 10 bagian berukuran sama. Sedangkan bagian 9 yang dipisahkan sebagai set pelatihan dan bagian yang tersisa dari rangkaian pengujian.

Dalam menilai kinerja model yang diusulkan digunakan *confusion matrix* yang berguna untuk model evaluasi klasifikasi. Dengan menggunakan *confusion matrix*, akurasi pengklasifikasi dapat dihitung dengan menggunakan persamaan (2.13). Tabel 1 menunjukkan *confusion matrix* dalam penelitian ini.

Tabel 22 *confusion matrix*

Prediksi	Aktual			
	Jati	Mahoni	Sengon	Mindi
Jati	Benar Jati	Bukan Jati	Bukan Jati	Bukan jati
Mahoni	Bukan Mahoni	Benar Mahoni	Bukan Mahoni	Bukan Mahoni
Sengon	Bukan Sengon	Bukan Sengon	Benar Sengon	Bukan Sengon
Mindi	Bukan Mindi	Bukan Mindi	Bukan Mindi	Benar Mindi

$$\text{Accuracy} = \frac{\sum \text{Benar (Jati, Mahoni, Sengon, Mindi)}}{\sum \text{Benar (...)} + \sum \text{Bukan (...)} \dots \dots \dots (2.13)$$

III. HASIL DAN PEMBAHASAN

Dalam makalah ini menggunakan alat data mining MATLAB dan RapidMiner untuk melakukan percobaan. Semua proses ekstraksi preprocessing dan tekstur dilakukan di MATLAB dan sistem identifikasi dilakukan oleh RapidMiner.

Pada tabel 2 memperlihatkan perbedaan variasi parameter *momentum* yang ada pada metode BPNN dengan batasan nilai dari 0.1 hingga 1. Hasil memperlihatkan bahwa terjadi penurunan secara signifikan sejak setingan momentum berada pada angka 0.6. Sehingga, dapat disimpulkan bahwa semakin kecil momentum yang digunakan akan

menghasilkan akurasi semakin tinggi. Dan hasil akurasi terbaik terlihat pada angka 0.1 dengan akurasi sebesar 98.27%.

Tabel 23 Akurasi BPNN berdasarkan variasi parameter *Momentum*

Cycles	Learning Rate	Momentum	Akurasi
500	0.3	0.1	98.27% +/- 1.61% (mikro: 98.27%)
500	0.3	0.2	97.41% +/- 1.89% (mikro: 97.41%)
500	0.3	0.3	97.40% +/- 3.04% (mikro: 97.41%)
500	0.3	0.4	97.62% +/- 2.65% (mikro: 97.62%)
500	0.3	0.5	96.97% +/- 2.61% (mikro: 96.98%)
500	0.3	0.6	97.40% +/- 1.90% (mikro: 97.41%)
500	0.3	0.7	97.62% +/- 2.47% (mikro: 97.62%)
500	0.3	0.8	60.66% +/- 5.80% (mikro: 60.69%)
500	0.3	0.9	41.91% +/- 4.68% (mikro: 41.90%)
500	0.3	1	24.41% +/- 1.01% (mikro: 24.41%)

Pada tabel 3 memperlihatkan perbedaan variasi parameter *learning rate* pada metode BPNN dengan batasan nilai dari 0.1 hingga 1. Hasil memperlihatkan bahwa terjadi kenaikan dan penurunan pada akurasi. Rentang nilai akurasi yang dihasilkan berkisar antara 96.11% hingga 98.27% Sedangkan hasil akurasi terbaik terlihat pada angka inputan 0.3 dengan akurasi sebesar 98.27%.

Tabel 24 Akurasi BPNN berdasarkan variasi parameter *Learning Rate*

Cycles	Learning Rate	Momentum	Akurasi
500	0.1	0.1	96.10% +/- 1.90% (mikro: 96.11%)
500	0.2	0.1	97.62% +/- 1.51% (mikro: 97.62%)
500	0.3	0.1	98.27% +/- 1.61% (mikro: 98.27%)
500	0.4	0.1	97.83% +/- 2.57% (mikro: 97.84%)
500	0.5	0.1	96.54% +/- 2.42% (mikro: 96.54%)
500	0.6	0.1	96.97% +/- 2.42% (mikro: 96.98%)
500	0.7	0.1	97.19% +/- 1.95% (mikro: 97.19%)
500	0.8	0.1	96.75% +/- 2.00% (mikro: 96.76%)
500	0.9	0.1	97.41% +/- 1.89% (mikro: 97.41%)
500	1	0.1	96.97% +/- 2.00% (mikro: 96.98%)

Pada tabel 4 memperlihatkan perbedaan variasi parameter *training cycle* pada metode BPNN dengan batasan nilai dari 100 hingga 1000. Hasil memperlihatkan bahwa terjadi kenaikan penurunan dan rentang akurasi yang dihasilkan berkisar antara 95.46% hingga 98.27%. Sedangkan hasil akurasi terbaik terlihat pada angka inputan 0.3 dengan akurasi sebesar 98.27%.

Tabel 25 Akurasi BPNN berdasarkan variasi parameter *Training Cycle*

Cycles	Learning Rate	Momentum	Akurasi
100	0.3	0.1	95.45% +/- 2.83% (mikro: 95.46%)
200	0.3	0.1	95.46% +/- 2.66% (mikro: 95.46%)
300	0.3	0.1	97.84% +/- 1.93% (mikro: 97.84%)
400	0.3	0.1	97.62% +/- 1.80% (mikro: 97.62%)
500	0.3	0.1	98.27% +/- 1.61% (mikro: 98.27%)

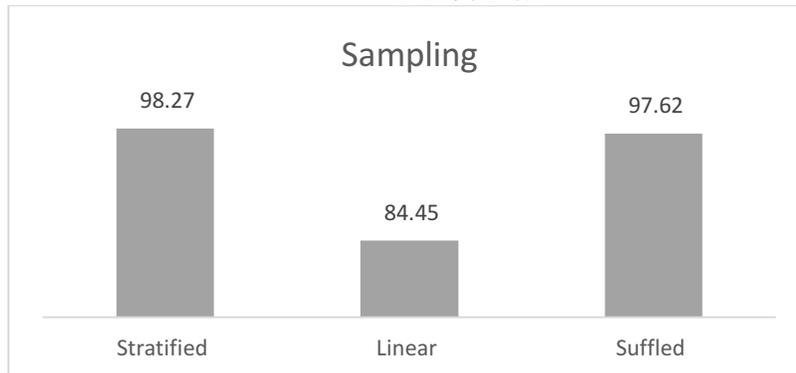
600	0.3	0.1	97.62% +/- 1.51% (mikro: 97.62%)
700	0.3	0.1	97.84% +/- 1.67% (mikro: 97.84%)
800	0.3	0.1	97.84% +/- 1.67% (mikro: 97.84%)
900	0.3	0.1	97.84% +/- 1.67% (mikro: 97.84%)
1000	0.3	0.1	97.84% +/- 1.36% (mikro: 97.84%)

Pada tabel 5 memperlihatkan penggunaan *fold validation* dengan batasan nilai dari 2 hingga 10. *Fold validation* digunakan sebagai tahap pengujian akhir. Hasil memperlihatkan bahwa semakin tinggi nilai *fold* mengakibatkan semakin tinggi akurasi yang dihasilkan. Sedangkan hasil akurasi terbaik terlihat pada inputan nilai 10-fold dengan akurasi sebesar 98.27%.

Tabel 26 Akurasi BPNN berdasarkan variasi nilai *Fold Validation*

fold validation	Cycles	Learning Rate	Momentum	Akurasi
2	500	0.3	0.1	96.11% +/- 0.44% (mikro: 96.11%)
3	500	0.3	0.1	96.76% +/- 2.43% (mikro: 96.76%)
4	500	0.3	0.1	95.90% +/- 1.28% (mikro: 95.90%)
5	500	0.3	0.1	96.33% +/- 1.87% (mikro: 96.33%)
6	500	0.3	0.1	96.55% +/- 1.21% (mikro: 96.54%)
7	500	0.3	0.1	98.06% +/- 1.34% (mikro: 98.06%)
8	500	0.3	0.1	96.55% +/- 2.86% (mikro: 96.54%)
9	500	0.3	0.1	96.75% +/- 2.61% (mikro: 96.76%)
10	500	0.3	0.1	98.27% +/- 1.61% (mikro: 98.27%)

Hasil yang dicapai dengan inputan *10-fold validation* mencapai akurasi hingga 98.27%. Dalam penelitian ini diuji juga penggunaan metode sampling antara *stratified sampling*, *linier sampling* dan *suffled sampling*. Hasil menunjukkan bahwa penggunaan metode *Stratified sampling* mencapai hasil keakurasian yang lebih tinggi dengan hasil 98.27%.



Gambar 9 Hasil *Sampling* terbaik

IV. KESIMPULAN

Penelitian ini, menggunakan 80 fitur gabungan hasil GLCM berfungsi baik sebagai ekstraksi fitur sebelum dilakukan klasifikasi dengan metode BPNN. Kerja metode BPNN dalam klasifikasi jenis kayu memberi nilai akurasi yang baik. Hasil akurasi yang didapatkan adalah 98.27%. Hasil tersebut didapat dari berbagai parameter BPNN yang telah di uji. Hasil pengujian menunjukkan bahwa kombinasi parameter seperti *momentum*, *learning rate*, dan *training cycle* mempengaruhi hasil akurasi. Selain parameter pada BPNN dan gabungan 80 fitur GLCM untuk masing-masing layer warna dan warna grayscale, metode sampling juga mempengaruhi hasil akurasi. Oleh karena itu, untuk usulan kedepan masih memungkinkan dapat dilakukan penelitian dengan menambahkan berbagai metode seperti seleksi fitur

maupun optimasi sehingga memungkinkan proses indentifikasi berjalan cepat dan diharapkan juga nilai akurasi dapat bertambah.

V. REFERENSI

- [1] M. Khalid, E. L. Y. Lee, R. Yusof, and M. Nadaraj, "Design of an Intelligent Wood Species Recognition System," *Int. J. Simul. Syst. Sci. Technol.*, vol. 9, no. 3, pp. 9–19, 2008.
- [2] 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.
- [3] I. N. I. N. Yuwono, R. A. R. A. Pramunendar, P. N. P. N. Andono, and R. A. R. A. Subandi, "the Quality Determination of Coconut Wood Density Using Learning Vector Quantization," *J. Theor. Appl. Inf. Technol.*, vol. 57, no. 1, pp. 82–88, 2013.
- [4] Z. Dong, "Automated recognition of wood damages using artificial neural network," *2009 Int. Conf. Meas. Technol. Mechatronics Autom. ICMTMA 2009*, vol. 3, pp. 195–197, 2009.
- [5] A. K. Singh, S. Tiwari, and V. P. Shukla, "Wavelet based Multi Class image classification using Neural Network," *Int. J. Comput. Appl.*, vol. 37, no. 4, pp. 21–25, 2012.
- [6] 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.
- [7] 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.