

ANALISIS PERFORMANSI SISTEM PENDETEKSI KUALITAS KAYU JATI MENGGUNAKAN PENGOLAHAN CITRA DENGAN METODE *HISTOGRAM OF ORIENTED GRADIENTS* DAN SUPPORT VECTOR MACHINE

PERFORMANCE ANALYSIS OF TEAK WOOD'S QUALITY DETECTION SYSTEM USING IMAGE PROCESSING WITH *HISTOGRAM OF ORIENTED GRADIENTS* AND SUPPORT VECTOR MACHINE

Haidy Anazmar¹, Dr. Ir. Jangkung Raharjo, M.T.², Rissa Rahmania, S.T., M.T.³

^{1,2,3}Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

¹haydianazmar@gmail.com, ²jangkung.raharjo@gmail.com, ³sanarahmani@telkomuniversity.ac.id

Abstrak

Jati merupakan salah satu jenis pohon yang memiliki banyak fungsi serta kegunaan. Kayu jati memiliki kualitas yang sangat tinggi untuk digunakan sebagai bahan baku pembuatan perabotan rumah seperti meja, kursi, lemari, dan lain-lain. Tetapi masih banyak pengusaha mebel yang sering keliru terhadap penilaian kualitas kayu jati. Hal tersebut mengakibatkan kurangnya kualitas kayu jati yang digunakan sebagai bahan baku untuk membuat peralatan rumah atau untuk kebutuhan bangunan.

Pada Tugas Akhir ini telah dilakukan penelitian kualitas kayu jati menggunakan metode *Histogram of Oriented Gradients* sebagai metode ekstraksi ciri dan metode *Support Vector Machine* sebagai metode klasifikasi. Metode *Histogram of Oriented Gradients* bertujuan untuk menghitung nilai gradien di daerah tertentu dari suatu objek. Kemudian diklasifikasi menggunakan *Support Vector Machine* karena dapat menemukan fungsi pemisah (*hyperplane*) yang bertujuan untuk memisahkan objek berbeda dengan klasifikasi yang berbeda.

Dari hasil pengujian diperoleh akurasi terbaik sebesar 96,67%. Akurasi diperoleh dari pengujian 144 citra menggunakan metode *Histogram of Oriented Gradients* pada *cell size* 20×20, *block size* 8×8, *bin numbers* 9, jenis kernel *Support Vector Machine polynomial* dan *multiclass One Against All*.

Kata Kunci: Kayu Jati, *Histogram of Oriented Gradients*, *Support vector Machine*

Abstract

Teak is one type of tree that has many functions as well as usability. Teak Wood has a very high quality to be used as raw material for home furnishing such as tables, chairs, cabinets, and others. But there are still many furniture entrepreneur who often mistakenly to the quality valuation of teak wood. This resulted in lack of teak wood quality used as raw material to make home appliances or for building needs.

The final project studies the quality of teak using the Histogram of Oriented Gradients method as a feature extraction method and the Support Vector Machine method as a classification method. The Histogram of Oriented Gradients method aims to calculate gradient values in a particular area of an object. The classification method uses Support Vector Machine because it can find a hyperplane function that aims to separate different objects with different classifications.

From the test results obtained the best accuracy of 96,67%. Accuracy was obtained from 144 test images using Histogram of Oriented Gradients in cell size 20×20, block size 8×8, bin numbers 9, polynomial Support Vector Machine kernel types and One Against All multiclass.

Keywords: Teak Wood, *Histogram of Oriented Gradients*, *Support Vector Machine*

1. Pendahuluan

Peradaban manusia sekarang ini membuat konsumsi terhadap kayu telah meningkat termasuk sebagai bahan baku mebel [1]. Kayu Jati merupakan salah satu jenis kayu yang memiliki kualitas sebagai bahan baku pembuatan mebel seperti pembuatan kursi, meja, lemari, dll. Kayu jati memiliki kualitas yang bagus, kuat, awet, serta bahan bakunya mudah didapatkan. Kayu jati memiliki sifat pertumbuhan yang cepat pada umur tertentu dan akan melambat pada periode-periode berikutnya [2]. Pada umumnya, umur kayu yang tua tidak menentukan kualitas kayu jati karena banyak kayu jati yang cacat saat baru tumbuh sehingga akan berpengaruh pada kualitas kayu jati tersebut. Buruknya kayu jati dapat dipengaruhi oleh alam seperti cacat mata kayu dan retak akibat proses pemindahan kayu tersebut [3]. Kayu jati dengan kualitas rendah akan mempengaruhi ketahanan dan kekuatan kayu tersebut. Hal tersebut menyebabkan banyak hasil produksi mebel yang mengalami kerusakan sebelum waktunya yang pasti mempengaruhi tingkat kepuasan dari konsumen.

Kayu jati pada dasarnya adalah jenis kayu unggul yang banyak digunakan oleh industri mebel sebagai bahan baku tapi biasanya masih kurang dalam memperhatikan kualitas dari kayu jati tersebut. Pada penelitian kayu jati sebelumnya, kualitas kayu jati yang baik jika umur kayu tersebut sudah cukup, pori-pori padat, warna kayu lebih jelas, tidak terdapat mata mati pada kayu, kayu tidak berlubang, dan tidak ada gubal pada kayu [4]. Kayu jati disukai karena pori kayu yang padat dan daya tahan tinggi [5]. Kualitas kayu juga dapat diketahui melalui pola dari pori kayu tersebut [6]. Dan kayu jati memiliki kemampuan bertahan yang tinggi terhadap perubahan kondisi lingkungan [7]. Sedangkan untuk kualitas kayu yang kurang baik adalah terdapat lubang pada kayu, adanya mata kayu, warna kayu lebih gelap, terdapat keretakan pada kayu [8].

Berdasarkan permasalahan diatas maka penulis berinisiatif membuat sistem yang dapat mengidentifikasi kualitas kayu jati menggunakan pengolahan citra digital dengan menggunakan metode *Support Vector Machine* (SVM) dan *Histogram of Oriented Gradient* (HOG) sebagai metode ekstraksi. Metode HOG dapat mengekstraksi citra berupa gambar dengan memunculkan nilai derajat keabuan piksel. Sedangkan SVM dipilih karena dapat memisahkan objek yang berbeda dengan klasifikasi yang berbeda. Penelitian sebelumnya yang menggunakan metode *Backpropagation* sebagai klasifikasi dan *Discrete Wavelet Transform* (DWT) sebagai ekstraksi cirinya mendapatkan tingkat akurasi sebesar 78,33% [4]. Pada penelitian lain yang menggunakan metode *Histogram of Oriented Gradients* dan *Support Vector Machine* untuk mendeteksi objek pejalan kaki pada aplikasi *mobile* mendapatkan akurasi sebesar 81,75% [9]. Diharapkan ketika menggunakan metode *Histogram of Oriented Gradients* dan *Support Vector Machine* untuk mendeteksi kualitas kayu jati akan mendapatkan akurasi yang lebih baik dari penelitian kualitas kayu jati sebelumnya.

2. Dasar Teori

2.1 Histogram of Oriented Gradients

HOG adalah salah satu metode ekstraksi ciri. Cara kerja dari HOG adalah dengan menghitung gradien dari setiap piksel di daerah tertentu. Setiap citra memiliki karakteristik yang ditunjukkan oleh *gradient distribution*. Untuk memperoleh informasi sebagai pembeda maka gambar akan dibagi menjadi beberapa *cell* yang dimana setiap *cell* akan dihitung sebagai HOG. Setiap *cell* memiliki nilai histogram yang berorientasi pada nilai-nilai gradien yang dihitung [10].

HOG memiliki langkah-langkah dalam menghitung nilai gradien pada daerah tertentu. Nilai gradien yang didapatkan dari perhitungan tiap piksel akan dibuat menjadi sebuah histogram. Langkah pertama yaitu menentukan *cell size* dan *block size*. Kemudian hitung nilai gradien dan orientasi gradien sesuai dengan *cell* yang telah ditentukan. Setiap *cell* tersebut akan dibuat histogram untuk mengetahui nilai dalam tiap *cell*. Langkah selanjutnya, menentukan bin orientasi dari nilai gradien yang berbeda untuk setiap *cell* [11]. Langkah terakhir ialah normalisasi blok untuk menghindari variasi iluminasi.

Langkah pertama adalah menentukan *cell size* dan *block size*. Proses selanjutnya ialah dengan menghitung nilai gradien dengan rumus sebagai berikut:

$$G = \sqrt{k_x(m,n)^2 + k_y(m,n)^2} \quad (2.1)$$

dimana G merupakan nilai gradien, k adalah citra *graylevel*. k_x merupakan matriks terhadap sumbu-x dan k_y merupakan matriks terhadap sumbu-y.

Nilai k_x merupakan nilai matriks terhadap sumbu f_x dan k_y merupakan nilai matriks terhadap sumbu f_y . Nilai f_x dan f_y didapat dengan menggunakan proses konvolusi melalui persamaan (2.2) dan (2.3).

$$k_x(m,n) = k \times f_x \quad (2.2)$$

$$k_y(m,n) = k \times f_y \quad (2.3)$$

dimana f_x adalah kernel $\begin{pmatrix} -1 & 0 & 1 \end{pmatrix}$ dan f_y adalah kernel $\begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix}$.

Dari nilai gradien tersebut akan digunakan untuk menentukan orientasi gradien dengan rumus:

$$|\Theta|(x,y) = \tan^{-1} \frac{k_y(m,n)}{k_x(m,n)} \quad (2.4)$$

Setelah mendapatkan nilai gradien dan orientasinya, maka akan dilakukan pembagian nilai bin dalam rentang 0° - 180° . Jika nilai *bin* = 9 maka, terdapat 9 daerah pembagian pada histogram 0° , 20° , 40° , 60° , 80° , 100° , 120° , 140° , dan 160° [12]. Setelah didapatkan nilai *bin*, maka selanjutnya melakukan proses normalisasi. Kemudian


nilai histogram dari setiap *cell* digabungkan ke dalam *block* yang telah normalisasi untuk membentuk vektor ciri yang akan dilanjutkan ke tahap klasifikasi.

2.2 Support Vector Machine

SVM merupakan sistem pemebelajaran yang menggunakan ruang hipotesis berupa fungsi-fungsi linier dalam sebuah ruang ciri berdimensi tinggi, dan dilatih menggunakan algoritma yang didasarkan teori optimasi dengan implementasi bias pembelajaran yang berasal dari teori pembelajaran statistik [13]. SVM berada satu kelas dengan ANN dalam hal fungsi dan kondisi permasalahan yang bisa diselesaikan dan keduanya masuk dalam kelas *supervised learning* [14].

SVM merupakan teknik yang dikembangkan oleh Vapnik dan dapat mengatasi beberapa kekurangan yang ada pada ANN [15]. Metode ini berasal dari teori pembelajaran statistik yang menjanjikan dan memberikan hasil yang lebih baik dibandingkan metode lainnya. SVM menggunakan teknik kernel harus memetakan data asli dari dimensi asalnya menjadi dimensi lain yang lebih tinggi. Pada metode ANN, selama proses pelatihan semua data latih akan dipelajari. SVM berbeda dengan ANN yaitu hanya data terpilih saja yang digunakan dalam klasifikasi yang akan dipelajari. ANN juga akan menyimpan semua data yang digunakan saat prediksi, sedangkan SVM hanya menyimpan sebagian data latih yang digunakan pada saat prediksi. Hal tersebut yang menjadi kelebihan dari metode SVM [13].

Ide dasar dari SVM ialah memaksimalkan batas *hyperplane* yang dijelaskan pada Gambar 2.1 berikut:



Gambar 2. 1 Margin Hyperplan pada SVM [16]

Konsep klasifikasi SVM ialah sebagai usaha untuk mencari *hyperplane* terbaik yang berfungsi untuk sebagai pemisah dua buah kelas data pada *input face* [17]. *Hyperplane* dapat ditemukan dengan mengukur margin dan mencari titik maksimalnya. Margin adalah jarak antara *hyperplane* dengan *pattern* terdekat dari masing-masing *class*. *Pattern* yang paling dekat ini disebut sebagai *support vector* [16]. Garis merah tebal pada Gambar 2.1 menunjukkan *hyperplane* terbaik yang terletak tepat pada tengah-tengah kedua *class*. Sedangkan titik lingkaran dan bujur sangkar yang mengenai garis titik-titik adalah *support vector*.

Gambar 2.4 memperlihatkan beberapa data yang merupakan anggota dari dua buah kelas yakni +1 dan -1. Bentuk lingkaran merupakan simbol data untuk kelas yang +1, sedangkan bujur sangkar untuk yang tergabung ke dalam kelas -1. Kernel yang digunakan pada penelitian ini yaitu *Polynomial*, RBF, dan *Linear*.

Ada beberapa fungsi kernel pada literatur SVM, yaitu sebagai berikut [16]:

1. Kernel *Linear*, kernel yang paling sederhana dari semua fungsi kernel, kernel yang biasanya digunakan dalam kasus klasifikasi teks. Berikut adalah rumus dari kernel *linear*:

$$K(x_i, x_t) = x_i \cdot x_t \quad (2.5)$$

2. Kernel *Radial Basic Function* (RBF), kernel yang umum digunakan untuk data yang sudah valid dan merupakan *default* dalam SVM. Berikut adalah rumus dari kernel RBF:

$$K(x_i, x_t) = \exp\left(-\frac{\|x_i - x_t\|^2}{2\sigma^2}\right) \quad (2.6)$$

3. Kernel *Polynomial*, kernel yang sering digunakan untuk klasifikasi gambar. Berikut adalah rumus dari kernel *polynomial*:

$$K(x_i, x_t) = (x_i \cdot x_t + c)^p \quad (2.7)$$

Dimana $K(x_i, x_t)$ = fungsi kernel, x_i = data uji, x_t = titik dataset, c = nilai konstanta, dan p = nilai ordo.

2.5.1 Multiclass SVM

SVM awalnya hanya untuk mengklasifikasi data ke dalam dua kelas. Namun SVM juga dapat digunakan untuk mengklasifikasi data yang terdiri lebih dari dua kelas. Ada beberapa pilihan untuk mengimplementasikan *multiclass* SVM yaitu salah satunya menggabungkan beberapa SVM *biner*. Berikut adalah metode yang umum digunakan dalam mengimplementasikan *multiclass* SVM [16]:

1. *One-against-all*, pada metode ini setiap model klasifikasi ke-I dilatih dengan menggunakan keseluruhan data yang bertujuan mencari solusi permasalahan.
2. *One-against-one*, pada metode terdapat beberapa model untuk melakukan pengujian setelah model klasifikasi selesai dibangun. Salah satunya adalah dengan menggunakan model voting.


Metode SVM dipilih karena memiliki beberapa kelebihan, diantaranya:

1. *Generalisasi*, yaitu kemampuan SVM sebagai metode mengklasifikasi yang tidak termasuk dalam pola.
2. Metode yang tepat untuk digunakan dalam memecahkan masalah berdimensi tinggi, dan dalam ketebatasan data yang ada.
3. SVM udah banyak digunakan secara global, sehingga memiliki kapasitas pengujian yang memenuhi.
4. *Feasibility*, yaitu SVM dapat relatif mudah diimplementasikan karena proses penentuan SVM dapat dirumuskan dalam QP *problem*.

Selain itu SVM juga memiliki kekurangan yaitu Metode SVM sulit digunakan dalam penelitian yang menggunakan data yang banyak [18].

2.3 Desain Sistem

Secara keseluruhan alur kerja sistem yang dirancang adalah: Pertama pengambilan citra kayu jati olahan, lalu dilanjutkan ke tahap *preprocessing* yang meliputi *cropping*, *resize*, citra *RGB to grayscale*, kemudian dilanjutkan proses ekstraksi ciri menggunakan HOG, dan terakhir menganalisa ciri dan diklasifikasi menggunakan SVM. Blok diagram tahapan dari proses perancangan sistem direpresentasikan pada diagram blok sistem seperti Gambar 2.2 berikut:



Gambar 2. 2 Diagram Blok Sistem

2.3 Parameter Performansi Sistem

Setelah melakukan proses training, testing dan deteksi maka perlu adanya pengujian performansi sistem. Pengujian dilakukan untuk mengetahui keberhasilan sistem pada pengaplikasian deteksi kualitas kayu jati. Performansi sistem diukur berdasarkan parameter berikut:

1. Akurasi Sistem

Akurasi adalah suatu pengukuran untuk pengecekan sistem antara nilai prediksi dengan nilai kenyataan, sehingga dapat menghasilkan nilai kebenaran. Jika nilai akurasi tersebut bernilai besar maka sistem tersebut baik untuk mendeteksi kualitas kayu jati. Secara matematis dapat dituliskan sebagai berikut:

$$N = \frac{x}{y} \times 100\% \quad (2.10)$$

dimana N = akurasi, x = jumlah data benar, dan y = jumlah data keseluruhan.

2. Waktu Komputasi

Waktu Komputasi adalah waktu yang diperlukan sistem dalam awal proses hingga akhir proses. Kalkulasi waktu yang dihasilkan dapat membantu prediksi pemrosesan secara efisien. Sehingga semakin kecil hasil waktu komputasi maka semakin efisien pemrosesan sistem tersebut. Secara matematis dapat dituliskan sebagai berikut:


$$t = t_1 - t_0 \quad (2.11)$$

dimana t = waktu komputasi, t_0 = waktu awal dan t_1 = waktu akhir.


3. Pembahasan

3.1 Pengaruh Perubahan *Cell Size* pada HOG

Pada skenario pertama, akan dilakukan pengujian dengan melihat pengaruh dari perubahan *cell size* tanpa merubah *block size*, *bin numbers*, kernel dan *multiclass* terhadap akurasi dan waktu komputasi. Dimana *cell size* yang diujikan yaitu 10×10 , 15×15 , 20×20 dan 25×25 . Sedangkan parameter lainnya yaitu *block size* 8×8 , *bin numbers* 9, dan parameter SVM yaitu jenis kernel *polynomial* serta *multiclass* OAA. Dari empat variasi *cell size* tersebut, didapatkan hasil performansi akurasi dan waktu komputasi *cell size* seperti yang terdapat pada Gambar 3.1 dan Gambar 3.2.



Gambar 3.1 Akurasi *Cell Size* pada HOG




Gambar 3.2 Waktu Komputasi *Cell Size* pada HOG


Berdasarkan Gambar 3.1 dan Gambar 3.2 didapatkan kesimpulan bahwa akurasi tertinggi yang didapatkan pada *cell size* 20×20 sebesar 96,67% dengan waktu komputasi sebesar 0,257 seconds. Hal ini didapatkan karena dengan ukuran *cell size* 20×20 dapat mengkodekan informasi bentuk citra kayu dengan maksimal dan juga membatasi jumlah vektor ciri pada HOG yang mengakibatkan waktu komputasi lebih cepat

3.2 Pengaruh Perubahan *Block Size* pada HOG

Pada skenario kedua, akan dilakukan pengujian dengan melihat pengaruh dari perubahan *block size* tanpa merubah *cell size*, *bin numbers*, kernel dan *multiclass* terhadap akurasi dan waktu komputasi. Dimana *block size* yang diujikan yaitu 2×2 , 4×4 , 8×8 , dan 10×10 . Sedangkan parameter lainnya yaitu *cell size* 20×20 , *bin numbers* 9 dan parameter SVM yaitu jenis kernel *polynomial* serta *multiclass* OAA. Dari empat variasi *block size* tersebut, didapatkan hasil performansi akurasi dan waktu komputasi *block size* seperti yang terdapat pada Gambar 3.3 dan Gambar 3.4.



Gambar 3.3 Akurasi *Block Size* pada HOG




Gambar 3.4 Waktu Komputasi *Block Size* pada HOG


Berdasarkan Gambar 3.3 dan Gambar 3.4 diperoleh kesimpulan bahwa akurasi tertinggi yang didapatkan pada *block size* 8x8 yaitu sebesar 96,67% dengan waktu komputasi sebesar 0,620 *seconds*. Ukuran *block size* 8x8 dapat menangkap perbedaan intensitas warna piksel lebih baik sehingga waktu komputasi lebih lama.

3.3 Pengaruh Perubahan *Bin Numbers* pada HOG

Pada skenario ketiga, dilakukan pengujian dengan melihat pengaruh dari perubahan *bin numbers* tanpa merubah *cell size*, *block size*, kernel dan *multiclass* terhadap akurasi dan waktu komputasi. Dimana *bin numbers* yang diujikan yaitu 9, 12, 15, dan 18. Sedangkan parameter lainnya yaitu *cell size* 20x20, *block size* 8x8 dan parameter SVM yaitu jenis kernel *polynomial* dan *multiclass* OAA. Dari empat variasi *bin numbers* tersebut, didapatkan hasil performansi akurasi dan waktu komputasi *bin numbers* seperti yang terdapat pada Gambar 3.5 dan Gambar 3.6.



Gambar 3.5 Akurasi *Bin Numbers* pada HOG




Gambar 3.6 Waktu Komputasi *Bin Numbers* pada HOG


Berdasarkan Gambar 3.5 dan Gambar 3.6 didapatkan kesimpulan bahwa akurasi tertinggi yang didapatkan pada *bin numbers* 9 sebesar 96,67% dengan waktu komputasi sebesar 0,372 *seconds*. Nilai akurasi yang sama saat *bin numbers* 9 dan 12 disimpulkan bahwa *bin numbers* 9 dan 12 merepresentasikan nilai histogram lebih baik tetapi waktu komputasi *bin numbers* 9 lebih cepat.

3.4 Pengaruh Perubahan Kernel pada SVM

Pada skenario terakhir, dilakukan pengujian dengan melihat pengaruh dari perubahan jenis kernel dan *multiclass* tanpa merubah *cell size*, *block size*, dan *bin numbers* terhadap akurasi dan waktu komputasi. Dimana kernel yang diujikan yaitu *Polynomial*, *RBF*, *Linear* serta *multiclass* terdiri yang dari OAA dan OAO. Sedangkan parameter lainnya yaitu *cell size* 20x20, *block size* 8x8 dan *bin numbers* 9. Dari tiga variasi kernel tersebut, didapatkan hasil performansi akurasi dan waktu komputasi setiap jenis kernel pada SVM dengan *multiclass* OAA dan OAO seperti yang terdapat pada Gambar 3.7 dan Gambar 3.8.



Gambar 3.7 Akurasi Kernel dan Multiclass SVM



Gambar 3.8 Waktu Komputasi Kernel dan Multiclass SVM

Berdasarkan Gambar 3.7 dan Gambar 3.8 didapatkan kesimpulan bahwa akurasi tertinggi didapatkan pada jenis kernel *polynomial* dan *multiclass* yang digunakan yaitu OAA dengan akurasi sebesar 96,67% dan waktu komputasi sebesar 0,361 seconds. Dapat disimpulkan bahwa jenis kernel *polynomial* dengan *multiclass* OAA menghasilkan akurasi terbaik.

4. Kesimpulan

Berdasarkan hasil pengujian sistem untuk mendeteksi kualitas kayu jati yang telah dilakukan dengan menggunakan metode ekstraksi ciri HOG dan metode klasifikasi SVM, didapatkan nilai akurasi terbaik yang dihasilkan adalah sebesar 96,67% dengan waktu komputasi 0,257 seconds. Parameter HOG yang digunakan adalah *cell size* 20×20, *block size* 8×8, dan *bin numbers* 9. Sedangkan untuk parameter SVM menggunakan jenis kernel *Polynomial* dengan *multiclass* OAA.

Daftar Referensi

- [1] S. M. Hosseini and M. Fadaei, "Characteristics of Particleboard Made from Sedar Chips and Wood Slabs," *International Journal of Engineering*, vol. 26, pp. 39-43, 2013.
- [2] Y. Suranto, T. A. Prayitno, D. Marsono and J. P. Gentur Sutapa, "Pengaruh Umur Pohon, Bonita, dan Posisi Aksial Batang Terhadap Struktur Makroskopis dan Kualitas Kayu Jati Sebagai Bahan Furnitur," *Jurnal Manusia dan Lingkungan*, vol. 22, pp. 84-93, 2015.
- [3] P. D. Wananda, L. Novamizanti and R. D. Atmaja, *Sistem Deteksi Cacat Kayu Dengan Metode Deteksi Tepi Susun dan Ekstraksi Ciri Statistik*, Bandung: Universitas Telkom, 2018.
- [4] E. P. Widodo, *Simulasi Pendeteksi Kualitas Kayu Jati Menggunakan Discrete Wavelet Transform dan Backpropagation*, Bandung: Universitas Telkom, 2017.
- [5] T. Pk and H. Bailleres, *Wood Quality for Advanced Uses of Teak from Natural and Planted Forests*, Vienna: International Union of Forest Research Organizations (IUFRO), 2017.
- [6] I. Gunawan, J. Halomoan and R. D. Atmaja, *Perancangan Sistem Identifikasi Kualitas Kayu Untuk Quality Kotrol Berbasis Pengolahan Citra Digital*, Bandung: Universitas Telkom, 2015.

- [7] D. S. Sivakumar, R. Vishnuvardhan and R. S. Kumar , "Fabrication and Characterisation of B-H-G Fiber with Teak Wood Particles Reinforced Hybrid Composit," *International Journal of Engineering & Technology* , vol. 7, pp. 208-211, 2018.
- [8] M. P. Praja Kusuma, R. D. Atmaja and S. Aulia, Implementasi Sistem Pendeteksi Cacat Pada Kayu Menggunakan Metode Gabor Wavelet Transform, Bandung: Universitas Telkom, 2015.
- [9] R. Ilmi, A. Novianty and U. A. Ahmad, Perancangan dan Implementasi Histogram of Oriented Gradients dan Support Vectoe Machine untuk Deteksi Obyek Pejalan Kaki Pada Aplikasi Mobile Berbasis Android, Bandung: Universitas Telkom, 2015.
- [10] H. Yang and X. A. Wang, "Cascade Classifier for Face Detection," *Journal of Algorithms & Computational Technology*, vol. 10, pp. 187-197, 2016.
- [11] R. U. Nur O and A. Kusumaningsih, "Deteksi Manusia dengan Menggunakan Histogram of Oriented Gradients dan Naive Bayes Classifier," Universitas Trunojoyo, Madura, 2017.
- [12] M. B. Pranoto, K. N. Ramadhani and A. Arifianto, "Face Detection System Menggunakan Metode Histogram of Oriented Gradients dan Support Vector Machine," *e-Proceeding of Engineering*, vol. 4, p. 5038, 2017.
- [13] N. K. Adi and R. R. Isnanto, "Support Vector Machine untuk Klasifikasi Citra Jenis Daging Berdasarkan Tekstur Menggunakan Ekstraksi ciri Gray Level CO-Occurance Matrices," *Jurnal Sistem Informasi Bisnis*, vol. 6, pp. 1-10, 2016.
- [14] P. A. Octaviani, Y. Wilandari and D. Ispriyanti, "Penerapan Metode Klasifikasi Support Vector Machine (SVM) Pada Data Akreditasi Sekolah Dasar (SD) DI Kabupaten Magelang," *Jurnal Gaussian*, vol. 3, pp. 811-820, 2014.
- [15] X. Zhou and J. Shen, "Least Squares Support Vector Machine for Constitutive Modeling of Clay," *International Journal of Engineering*, vol. 28, pp. 1571-1578, 2015.
- [16] K. Sembiring, Penerapan Teknik Support Vector Machine untuk Pendeteksian Intrusi pada Jaringan, Bandung: Institut Teknologi Bandung, 2007.
- [17] H. Dehghan, A. A. Pouyan and H. Hassanpour, "Detection of Alzheimer's Disease Using Multitracer Positron Emission Tomography Imaging," *International Journal of Engineering*, vol. 27, pp. 51-56, 2014.
- [18] A. S. Nugroho, A. B. Witarto and D. Handoko, "Support Vector Machine Teori dan Aplikasinya dalam Bioinformatika," in *Proceeding of Indonesian Scientific Meeting in Central Japan*, Gifu, 2003.