



TESIS - EE185401

KLASIFIKASI KEKUATAN KAYU BERDASARKAN WARNA DAN TEKSTUR CITRA MENGUNAKAN METODE KNN

OKTA DHIRGA SUKRISDYANTO
07111750067015

DOSEN PEMBIMBING
Dr. I Ketut Eddy Purnama, ST., MT.
Dr. Supeno Mardi Susiki Nugroho, ST., MT.

PROGRAM MAGISTER
BIDANG KEAHLIAN TELEMATIKA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2019



TESIS - EE185401

**KLASIFIKASI KEKUATAN KAYU
BERDASARKAN WARNA DAN TEKSTUR CITRA
MENGUNAKAN METODE KNN**

**OKTA DHIRGA SUKRISDYANTO
07111750067015**

**DOSEN PEMBIMBING
Dr. I Ketut Eddy Purnama, ST., MT.
Dr. Supeno Mardi Susiki Nugroho, ST.,MT.**

**PROGRAM MAGISTER
BIDANG KEAHLIAN TELEMATIKA
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNOLOGI ELEKTRO
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2019**

LEMBAR PENGESAHAN TESIS

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar

Magister Teknik (MT)

di

Institut Teknologi Sepuluh Nopember

Oleh:

OKTA DHIRGA SUKRISDYANTO

NRP: 07111750067015

Tanggal Ujian: 26 Juni 2019

Periode Wisuda: September 2019

Disetujui oleh:

Pembimbing:

1. Dr. I Ketut Eddy Purnama, ST., MT.
NIP: 196907301995121001

2. Dr. Supeno Mardi Susiki N., ST., MT.
NIP: 197003131995121001

Penguji:

1. Dr.Ir. Wirawan, DEA.
NIP: 196311091989031011

2. Dr.Ir. Achmad Mauludiyanto, MT.
NIP: 196109031989031001

3. Dr. Eko Mulyanto Yuniarno, S.T., M.T.
NIP: 196806011995121009



Kepala Departemen Teknik Elektro
Fakultas Teknologi Elektro

Dr. Eng. Ardyono Priyadi, ST., M.Eng.

NIP: 07309271998031004

Halaman ini sengaja dikosongkan

PERNYATAAN KEASLIAN TESIS

Dengan ini saya menyatakan bahwa isi keseluruhan Tesis saya dengan judul “**KLASIFIKASI KEKUATAN KAYU BERDASARKAN WARNA DAN TEKSTUR CITRA MENGGUNAKAN METODE KNN**” adalah benar-benar hasil karya intelektual mandiri, diselesaikan tanpa menggunakan bahan-bahan yang tidak diijinkan dan bukan merupakan karya pihak lain yang saya akui sebagai karya sendiri.

Semua referensi yang dikutip maupun dirujuk telah ditulis secara lengkap pada daftar pustaka. Apabila ternyata pernyataan ini tidak benar, saya bersedia menerima sanksi sesuai peraturan yang berlaku.

Surabaya, Juni 2019

Okta Dhirga Sukrisdyanto
NRP. 07111750067015

Halaman ini sengaja dikosongkan

KLASIFIKASI KEKUATAN KAYU BERDASARKAN WARNA DAN TEKSTUR CITRA MENGUNAKAN METODE KNN

Nama mahasiswa : Okta Dhirga Sukrisdyanto
NRP : 07111750067015
Pembimbing : 1. Dr. I Ketut Eddy Purnama, ST., MT.
2. Dr. Supeno Mardi Susiki Nugroho, ST., MT.

ABSTRAK

Salah satu faktor terpenting dalam menentukan peruntukan olahan kayu adalah dengan mengetahui tingkat kekuatannya. Sebagai contoh, khusus untuk pemanfaatan kayu dalam konstruksi/bangunan disyaratkan kayu harus kuat, keras, berukuran besar dan awet. Akan sangat berbahaya, jika kayu yang dipilih tidak sesuai dengan spesifikasi yang telah ditentukan di atas. Selama ini, kekuatan kayu diukur menggunakan uji laboratorium yang relatif mahal baik untuk beli maupun sewa, serta bersifat merusak kayu uji. Alternatif yang bisa digunakan untuk menentukan tingkat kekuatan kayu adalah dengan mengamati karakteristik kayu menggunakan mata telanjang. Namun hal ini juga tidaklah mudah karena harus dilakukan oleh ahli kayu yang benar-benar hafal dan paham sifat karakteristik dari tiap kelas kayu. Oleh karena itu diperlukan suatu metode berbasis pengolahan citra yang dapat mempermudah mengidentifikasi kekuatan kayu dengan mudah, murah dan tidak merusak kayu uji.

Obyek yang digunakan dalam penelitian ini yaitu 7 (tujuh) jenis kayu yang terdiri dari: sengon laut (*Paraserianthes falcataria*), sengon tekik (*Paraserianthes falcataria*), trembesi (*Samanea Saman*), waru (*Hibiscus tiliaceus*), mahoni (*Swietenia mahagoni*), jati (*Tectona grandis*), dan akasia (*Acacia mangium*). Berdasarkan hasil pengukuran, sengon laut dan sengon tekek termasuk Kelas IV, trembesi dan waru termasuk Kelas III, sedangkan mahoni, jati dan akasia termasuk Kelas II. Kayu sengon laut merupakan kayu yang paling lemah karena hanya memiliki berat jenis 0,35. Sedangkan akasia merupakan kayu yang terkuat dengan berat jenis 0,74.

Parameter yang digunakan untuk menentukan kekuatan kayu berbasis pengolahan citra adalah warna dan tekstur kayu. Penelitian ini menggunakan metode ekstraksi fitur berupa nilai rerata histogram dari tiap kanal RGB dan nilai statistik dari metode *Gray-Level Co-Occurrence Matrix* (GLCM). Metode yang digunakan untuk seleksi fitur adalah *Recursive Feature Elimination Cross Validation* (RFECV). Sedangkan untuk klasifikasi menggunakan lima algoritma klasifikasi, yaitu *K-Nearest Neighbor* (KNN), *Linear Discriminant Analysis* (LDA), *Classification and Regression Tree* (CART), *Random Forest* (RF), dan *Support Vector Machine* (SVM). Hasil dari penelitian ini, performa tertinggi didapatkan dengan metode KNN dengan akurasi mencapai 95%, *precision* sebesar 95%, *recall* sebesar 94%, *f1-score* sebesar 94% dan nilai AUC sebesar 98%.

Meskipun di bawah performa KNN, performa keempat algoritma yang lain juga tidak buruk karena nilai rata-rata akurasi masih di atas 85%. Dengan hasil klasifikasi yang cukup bagus, metode ini bisa digunakan sebagai alternatif dalam menentukan tingkat kekuatan kayu.

Kata kunci: klasifikasi, kekuatan kayu, pengolahan citra, KNN, GLCM

WOOD STRENGTH CLASSIFICATION BASED ON RGB COLOR AND IMAGE TEXTURE USING KNN METHOD

By : Okta Dhirga Sukrisdyanto
Student Identity Number : 07111750067015
Supervisor(s) : 1. Dr. I Ketut Eddy Purnama, ST., MT.
2. Dr. Supeno Mardi Susiki Nugroho, ST., MT.

ABSTRACT

One of the most important factors for deciding the use of wood products is knowing its strength class. For example, the use of wood in building construction must be strong, hard, big and durable. It will be very dangerous, if the selected wood is not in accordance with the specifications above. So far, the wood strength has been measured using relatively expensive laboratory tests both for purchase and rent. In addition, this test has also damaged the test wood. An alternative method that can be used to determine the strength class of woods is to observe their characteristics using the naked eye. However, this is also a tough challenge because it must be done by wood experts who truly memorize and understand the characteristics of each wood class. Therefore, an image processing method is needed to identify the strength of wood easily, cheaply and not to damage test wood.

The object of this study consisted of seven types of wood: sengan laut (*Paraserianthes falcataria*), sengan tekik (*Paraserianthes falcataria*), trembesi (*Samanea Saman*), waru (*Hibiscus tiliaceus*), mahoni (*Swietenia mahagoni*), jati (*Tectona grandis*) and akasia (*Acacia mangium*). Based on the measurement results: sengan laut and sengan tekek were Class IV, trembesi and waru were Class III, while mahoni, jati and akasia were Class II. Sengan laut is the weakest wood because it only has a specific gravity of 0.35. Whereas akasia is the strongest wood with a specific gravity of 0.74.

The parameters used to determine the strength of wood based on image processing are the RGB color and texture of the wood image. This study uses two feature extraction methods, the average RGB histogram value for each color channel and the static characteristics of the *Gray-Level Co-Occurrence Matrix* (GLCM) method. The methods used for feature selection are *Recursive Feature Elimination* and *Cross Validation* (RFECV). While for data classification we use five algorithms: *K-Nearest Neighbor* (KNN), *Linear Discriminant Analysis* (LDA), *Classification and Regression Tree* (CART), *Random Forest* (RF), dan *Support Vector Machine* (SVM). The results of this study, the highest performance was obtained by the KNN method with an accuracy of 95%, precision at 95%, recall 94%, f1 score 94% and AUC value 98%.

Although below the KNN performance, the performances of the other four algorithms were also not bad because the average values of accuracy were

still above 85%. With a fairly good classification result, this method can be used as an alternative in determining the strength class of wood.

Key words: classification, wood strength, image processing, KNN, GLCM

KATA PENGANTAR

Alhamdulillah, segala puji bagi Allah karena hanya dengan kehendak-Nya penulisan tesis yang berjudul “**Klasifikasi Kekuatan Kayu Berdasarkan Warna dan Tekstur Citra Menggunakan Metode KNN**” ini dapat selesai tepat waktu. Shalawat dan salam semoga selalu terlimpah pada Nabi Muhammad, keluarga, sahabat dan para pengikutnya hingga akhir zaman.

Dalam menyelesaikan tesis ini, penulis mendapatkan banyak bantuan baik berupa pengajaran, bimbingan, arahan dan dukungan moril dari berbagai pihak. Oleh karena itu, rasa terima kasih dan penghargaan tak lupa penulis sampaikan kepada Bapak, Ibu, Mertua, Istri, Anak dan seluruh keluarga yang selalu mendoakan dan memotivasi penulis. Terima kasih kepada Dr. I Ketut Eddy Purnama, ST., MT. selaku pembimbing pertama dan Dr. Supeno Mardi Susiki Nugroho, ST., MT. selaku pembimbing kedua yang dengan penuh perhatian dan kesabaran selalu meluangkan waktu untuk memberikan pengarahan, bimbingan serta motivasi di tengah-tengah kesibukannya.

Perkenankanlah juga, penulis menyampaikan ucapan terima kasih kepada semua pihak yang terlibat dalam penyelesaian studi ini, kepada:

1. Pemerintah Kabupaten Trenggalek yang telah memberikan kesempatan dan beasiswa Program Magister (S2) Bidang Keahlian Telematika Konsentrasi Pengelola TIK Pemerintahan (PeTIK) pada Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember Surabaya;
2. Prof. Dr. Ir. Mochamad Ashari, M.Eng., selaku Rektor Institut Teknologi Sepuluh Nopember Surabaya;
3. Dr. Tri Arief Sardjono, S.T., M.T. selaku Dekan Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember Surabaya;
4. Dr. Eng. Ardyono Priyadi, S.T., M.Eng. selaku Kepala Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember Surabaya;
5. Dr. Ir. Wirawan, DEA selaku Dosen Wali Akademik dan Kepala Program Pascasarjana Departemen Teknik Elektro, Fakultas Teknologi Elektro,

Institut Teknologi Sepuluh Nopember Surabaya;

6. Dr. Adhi Dharma Wibawa, S.T., M.T. selaku Koordinator Bidang Keahlian Telematika/Pengelola TIK Pemerintahan (PeTIK) pada Departemen Teknik Elektro, Fakultas Teknologi Elektro, Institut Teknologi Sepuluh Nopember Surabaya;
7. Seluruh dosen dan staf pada Program Studi Magister (S2) Departemen Teknik Elektro khususnya Bidang Keahlian Telematika/Pengelola TIK Pemerintahan (PeTIK) atas pengabdianannya dalam membimbing kami;
8. Semua rekan-rekan PeTIK 2017 yang selalu memberikan inspirasi kehidupan. Semoga selalu kompak dan saling mendoakan baik selama perkuliahan maupun setelah kelulusan;
9. Serta semua pihak yang tidak dapat penulis sebutkan satu persatu.

Penulis menyadari bahwa tesis ini masih banyak kekurangan. Oleh karena itu, saran dan kritik yang membangun, khususnya untuk perbaikan, sangat diharapkan demi penyempurnaan tesis ini.

Surabaya, Juni 2019

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN TESIS	iii
PERNYATAAN KEASLIAN TESIS	v
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan	5
1.4 Batasan Masalah	5
1.5 Kontribusi	5
BAB 2 KAJIAN PUSTAKA	7
2.1 Kajian Penelitian Terkait	7
2.2 Teori Dasar	9
2.2.1 Kekuatan Kayu	9
2.2.2 Ekstraksi Fitur	14
2.2.2.1 Kanal Citra RGB	16
2.2.2.2 Gray Level Co-Occurence Matrix (GLCM)	17
2.2.3 Seleksi Fitur	20
2.2.4 Klasifikasi	21
2.2.4.1 K-Nearest Neighbours (KNN)	21
2.2.4.2 Linear Discriminant Analysis (LDA)	23
2.2.4.3 Decision Tree	24
2.2.4.4 Random Forest	25
2.2.4.5 Support Vector Machine (SVM) Classification	26

2.2.5	Evaluasi Model	28
BAB 3 METODE PENELITIAN		35
3.1	Uji Kekuatan Kayu	36
3.2	Pengambilan Gambar	38
3.3	<i>Pre-Processing</i>	39
3.4	Ekstraksi dan Seleksi Fitur	40
3.5	Klasifikasi dan Evaluasi Model	43
BAB 4 HASIL DAN PEMBAHASAN		47
4.1	Uji Kekuatan Kayu dan Pelabelan	47
4.2	Pengambilan Gambar dan <i>Pre-Processing</i>	52
4.3	Ekstraksi dan Seleksi Fitur	54
4.4	Klasifikasi Data dan Evaluasi Model	62
4.4.1	Data Training	62
4.4.1.1	Uji Performa Algoritma Klasifikasi	63
4.4.1.2	Uji Seleksi Fitur	69
4.4.1.3	Uji Parameter	72
4.4.2	Data Testing	76
BAB 5 KESIMPULAN		79
5.1	Kesimpulan	79
5.2	Saran	80
DAFTAR PUSTAKA		81
LAMPIRAN		85

DAFTAR GAMBAR

Gambar 1.1 Kelas kuat beberapa kayu di Indonesia	2
Gambar 2.1 Histogram Warna RGB	17
Gambar 2.2 Alur Ekstraksi Fitur pada GLCM.....	18
Gambar 2.3 Ilustrasi Algoritma KNN	22
Gambar 2.4 Ilustrasi Algoritma <i>Decision Tree</i>	24
Gambar 2.5 Ilustrasi Algoritma <i>Random Forest</i>	25
Gambar 2.6 Cara kerja SVM (Nugroho, 2008).....	26
Gambar 2.7 Cara kerja OAOSVM dan OAASVM.....	27
Gambar 2.8 Ilustrasi <i>10-Fold Cross Validation</i>	28
Gambar 2.9 <i>Box and Whisker Plot</i>	29
Gambar 2.10 Penentuan Batas-Batas Box-plot.....	30
Gambar 2.11 <i>Confusion Matrix</i>	31
Gambar 2.12 Kurva ROC.....	32
Gambar 3.1 Diagram Alir Klasifikasi Kekuatan Kayu	35
Gambar 3.2 Alat dan Kayu Uji	36
Gambar 3.3 Ilustrasi Pengambilan Gambar	38
Gambar 3.4 Langkah Pengambilan Gambar	39
Gambar 3.5 Citra RGB (a), Citra <i>Grayscale</i> (b)	40
Gambar 3.6 Histogram Citra Kayu Akasia (a) dan Sengon Tekek (b)	41
Gambar 3.7 Alur Seleksi Fitur	42
Gambar 3.8 Alur Klasifikasi dan Evaluasi Model	43
Gambar 4.1 Pengukuran Kadar Air Kayu pada Sengon Laut	47
Gambar 4.2 Menimbang Balok Kayu Mahoni	48
Gambar 4.3 Pengukuran Volume Kayu	49
Gambar 4.4 Sampel Gambar Mentah Hasil Foto	52
Gambar 4.5 Citra setelah <i>Pre-processing</i>	54
Gambar 4.6 Perbandingan Citra RGB dan <i>Grayscale</i>	55
Gambar 4.7 Seleksi Fitur GLCM dengan Estimator LDA.....	58
Gambar 4.8 Seleksi Fitur GLCM dengan Estimator LR.....	59
Gambar 4.9 <i>Tuning</i> Parameter $k_neighbors$ KNN.....	63
Gambar 4.10 <i>Tuning</i> parameter $n_estimator$ pada RF	64
Gambar 4.11 <i>Boxplot</i> Hasil Klasifikasi Berdasarkan Akurasi	65
Gambar 4.12 <i>Confusion Matrix</i> Data Training	66
Gambar 4.13 Pengukuran <i>Precision</i> , <i>Recall</i> dan <i>F1-score</i> pada Data Training ...	67
Gambar 4.14 Kurva ROC dan Nilai AUC	68
Gambar 4.15 Akurasi 16 Fitur vs 11 Fitur	70
Gambar 4.16 Kurva ROC untuk 16 Fitur.....	71
Gambar 4.17 Perbandingan Nilai AUC-ROC pada 16 Fitur dan 11 Fitur	72
Gambar 4.18 Akurasi Fitur Warna vs Fitur Tekstur vs 11 Fitur.....	74
Gambar 4.19 Nilai AUC Tiap Parameter	75
Gambar 4.20 <i>Confusion Matrix</i> dari Data Testing.....	76

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 2.1 Klasifikasi Kekuatan Kayu	10
Tabel 2.2 Hubungan Antara Sifat-Sifat dan Berat Jenis Kadar Air 12%.....	12
Tabel 2.3 Kelas Kuat Kayu Obyek Penelitian	13
Tabel 3.1 Kelas Kuat Kayu Berdasarkan Berat Jenis	37
Tabel 4.1 Pengukuran Massa Kayu.....	49
Tabel 4.2 Hasil Pengukuran Volume Kayu.....	50
Tabel 4.3 Hasil Pengukuran Kelas Kuat Kayu.....	50
Tabel 4.4 Validasi Kelas Kuat Kayu dan Pelabelan	51
Tabel 4.5 Rincian Pengambilan Data Citra.....	53
Tabel 4.6 Nilai Ekstraksi Fitur Warna RGB	56
Tabel 4.7 Sampel Ekstraksi Fitur GLCM	57
Tabel 4.8 Akurasi Per Jumlah Fitur Menggunakan RFE	60
Tabel 4.9 Rangkang Fitur Berurutan dari yang Terbesar	61
Tabel 4.10 Transformasi Data Menggunakan <i>MinMaxScaler</i>	62
Tabel 4.11 Hasil Klasifikasi Data <i>Training</i> Menggunakan 10-Fold CV	64
Tabel 4.12 Waktu Pemrosesan Tiap Klasifikasi	69
Tabel 4.13 Hasil Klasifikasi Menggunakan 16 Fitur	69
Tabel 4.14 Nilai <i>Recall</i> , <i>Precision</i> , <i>F1-score</i> pada 16 Fitur dan 11 Fitur.....	71
Tabel 4.15 Hasil Akurasi Menggunakan Fitur Warna	73
Tabel 4.16 Hasil Akurasi Menggunakan Fitur Tekstur.....	73
Tabel 4.17 Nilai <i>Recall</i> , <i>Precision</i> , <i>F1-score</i> Tiap <i>Parameter</i>	74
Tabel 4.18 Model Evaluation.....	77

Halaman ini sengaja dikosongkan

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Sebagai negara yang beriklim tropis, Indonesia memiliki kekayaan sumber daya alam kayu yang berlimpah. Tidak hanya dari segi jumlah, namun varietasnya juga sangat beragam yaitu kurang lebih terdapat 4.000 jenis kayu (Martawijaya et al., 2014). Akan tetapi hingga saat ini hanya sekitar 400 jenis yang memiliki nilai ekonomi dan sekitar 260 jenis yang telah digolongkan sebagai kayu perdagangan. Kayu-kayu tersebut berasal dari hutan alam, hutan tanaman dan tanaman rakyat. Saat ini ketersediaan kayu dari hutan alam semakin menurun, sementara hasil kayu dari hutan tanaman belum dapat mencukupi kenaikan kebutuhan kayu yang semakin meningkat. Sehingga perlu digalakkan penanaman untuk jenis kayu tanaman rakyat khususnya sebagai bahan baku bangunan.

Sejak dulu hingga sekarang fungsi kayu seakan belum ada yang bisa menggantikan, mulai dari bahan baku rumah, perkapalan, mebel, alat olahraga hingga ukiran dan kerajinan tangan. Hal ini tidak lepas dari kelebihan kayu dibandingkan material yang lain, di antaranya: memiliki berat yang lebih ringan dibanding beton dan baja, mempunyai daya tarik artistik karena memiliki tekstur alami, serta merupakan sumber daya yang dapat dibudidayakan sehingga memiliki nilai ekonomis yang cukup tinggi. Kelebihan lain yang menjadikan kayu masih sebagai primadona meskipun banyak material baru lain adalah karena lebih tahan terhadap tekanan dan lenturan. Sehingga bila terjadi guncangan yang hebat semisal gempa, penyangga bangunan yang terbuat dari kayu tidak mudah patah. Kayu juga mudah diolah dan dibentuk sesuai dengan keinginan karena mudah untuk dipaku dan direkatkan. Selain itu, kayu juga dapat diubah menjadi bentuk *pulp* (bubur kayu) untuk diolah menjadi bahan produk lainnya, seperti bahan baku pembuatan kertas.

Meskipun mempunyai banyak kelebihan, pemanfaatan kayu harus dilakukan secara selektif agar sesuai antara biaya yang dikeluarkan dan kualitas yang didapatkan. Pemilihan dan penggunaan kayu untuk suatu tujuan pemakaian,

memerlukan pengetahuan tentang sifat-sifat kayu. Hal ini sangatlah penting, karena dengan mengetahui sifat-sifat kayu akan memudahkan kita untuk memilih kayu yang cocok sesuai kebutuhan. Selain itu, juga dapat digunakan sebagai referensi dalam mencari alternatif kayu lain untuk fungsi yang sama jika kayu yang utama sudah langka atau harganya terlalu mahal. Faktor terpenting dalam menentukan peruntukan olahan kayu adalah dengan mengetahui tingkat kekuatannya. Salah satu contoh, khusus untuk pemanfaatan kayu dalam konstruksi/bangunan disyaratkan kayu harus kuat, keras, berukuran besar dan awet. Akan sangat berbahaya, jika kayu yang dipilih tidak sesuai dengan spesifikasi yang telah ditentukan tersebut. Sebaliknya, untuk alat gambar, kayu yang digunakan harus memiliki kriteria ringan, tekstur halus dan warna bersih (Dirjen Kehutanan, 1976).



Gambar 1.1 Kelas kuat beberapa kayu di Indonesia

Di Indonesia, secara umum kelas kayu berdasarkan kekuatan dibagi menjadi lima kelas, mulai Kelas I yang terkuat sampai kelas V yang terlemah.

Klasifikasi kekuatan kayu biasanya diukur berdasarkan uji berat jenis, kekuatan elastis, atau kekuatan tekan. Berat jenis kayu dapat ditentukan berdasarkan berat kayu kering oven atau kering udara dan volume kayu pada posisi kadar air. Kekuatan elastis ditentukan menurut tegangan elastis maksimum yang diterima oleh kayu sampai putus (tegangan elastis mutlak). Sedangkan kekuatan tekan ditentukan menurut tegangan tekan maksimum yang diterima oleh kayu sampai pecah (tegangan desakan mutlak). Secara umum kekuatan kayu berbanding lurus dengan berat jenis (Oey, 1990). Pada Gambar 1.1 kami sajikan beberapa contoh kelas kuat kayu di Indonesia berdasarkan berat jenisnya (P3HH-Pusat Penelitian dan Pengembangan Hasil Hutan, 2008).

Untuk kegunaan ideal, umumnya Kelas I dan Kelas II direkomendasikan sebagai bahan baku bangunan/konstruksi, bantalan kereta api, tiang listrik dan bidang perkapalan. Untuk kayu kelas III dan sebagian kelas II paling cocok digunakan sebagai bahan mebel, serta rangka pintu dan jendela. Sedangkan untuk kayu yang masuk dalam kelas IV dan V biasanya digunakan untuk bahan baku korek api, alat tulis serta bahan pembungkus (Dirjen Kehutanan, 1976).

Alternatif yang bisa digunakan untuk menentukan tingkat kekuatan kayu adalah dengan mengamati karakteristik kayu atau yang biasa dikenal dengan istilah makroskopik. Di antaranya bisa terlihat melalui kerapatan, warna, arah serat dan pori kayu (Ruffinatto, Crivellaro and Wiedenhoeft, 2015) serta ada atau tidaknya cacat kayu (Hongbo, Dawei and Mingming, 2010). Semakin tinggi kerapatan suatu kayu maka dapat dipastikan kayu tersebut semakin keras dan kuat. Kayu yang berasal dari pohon yang lebih tua biasanya mempunyai warna yang lebih gelap bila dibandingkan dengan bagian kayu yang berasal dari pohon yang lebih muda dari jenis yang sama. Kayu yang kering berbeda pula warnanya bila dibandingkan dengan warna kayu yang basah.

Arah serat adalah arah umum sel-sel kayu terhadap sumbu batang pohon. Secara umum terbagi menjadi sejajar arah serat (axial) dan tegak lurus arah serat (tangensial dan radial). Kekuatan terbesar yang dapat ditahan oleh kayu adalah sejajar arah serat, sedangkan kekuatan tarikan tegak lurus arah serat lebih kecil dari pada sejajar serat. Kayu juga dapat menahan beban desak, baik tekanan sejajar serat maupun tegak lurus serat, misalnya sebagai bantalan kereta api. Daya

tahan desak tegak lurus serat lebih kecil bila dibandingkan dengan sejajar serat. Pori kayu sangat berhubungan erat dengan arah serat. Pori merupakan sel pembuluh berbentuk seperti tabung, yang saling berhubungan untuk membentuk suatu sistem saluran. Secara umum, semakin banyak pori maka kayu semakin ringan, dan sebaliknya, kayu yang memiliki sedikit pori maka semakin berat dan kuat. Sedangkan yang dimaksud cacat kayu adalah menurunnya kekuatan kayu akibat adanya/terjadinya retak-retak, pecah-pecah, belah, pelapukan karena cuaca, serangan serangga atau jamur.

Meskipun bisa diamati dengan mata telanjang, namun tidak semua orang bisa melakukannya karena butuh pengalaman yang panjang dan harus mengenal karakteristik dari tiap-tiap kayu. Hasil identifikasi kekuatan kayu menggunakan mata telanjang juga sangat subyektif sesuai dengan pengalaman dan pengetahuan tiap-tiap peneliti. Sehingga sampai saat ini, untuk mengukur kekuatan kayu masih mengandalkan uji laboratorium yang harganya relatif mahal dan merusak kayu uji.

1.2 Rumusan Masalah

Sampai saat ini klasifikasi kekuatan kayu hanya bisa dilakukan melalui uji lab, baik berdasarkan pengukuran berat jenis, kekuatan elastis, atau kekuatan tekan kayu. Kelebihan uji lab tentunya hasil pengklasifikasian lebih valid karena menggunakan peralatan berpresisi tinggi. Meskipun demikian, uji lab memiliki beberapa kekurangan, di antaranya: membutuhkan biaya yang cukup mahal serta bersifat destruktif, sehingga merusak kayu uji.

Alternatif lain untuk menentukan tingkat kekuatan kayu adalah dengan cara manual yaitu mengamati karakteristik fisik kayu menggunakan mata telanjang. Untuk cara kedua ini hanya bisa dilakukan oleh ahli kayu yang mempunyai jam terbang tinggi dan benar-benar memahami karakteristik tiap kayu. Dengan mengadopsi teknologi pengolahan citra dan *machine learning*, cara manual di atas bisa dikembangkan agar bisa digunakan secara massal untuk mengidentifikasi kelas kuat kayu.

1.3 Tujuan

Tujuan utama yang ingin dicapai dari penelitian ini adalah memperoleh cara pengidentifikasian kekuatan kayu yang mempunyai akurasi tinggi, mudah, murah, serta tidak bersifat destruktif terhadap kayu uji. Metode pengidentifikasian berbasis pengolahan citra dengan parameter utama yaitu warna dan tekstur citra kayu. Adapun untuk pengklasifikasian menggunakan metode K-Nearest Neighbor (KNN).

1.4 Batasan Masalah

Dalam penelitian ini, ruang lingkup masalah dibatasi sebagai berikut:

1. Klasifikasi kekuatan kayu didapatkan berdasarkan pada pengujian berat jenis kayu.
2. Kayu yang digunakan untuk pengujian merupakan kayu lokal yang sering digunakan untuk bahan baku pembuatan rumah dan mebel.
3. Citra yang digunakan untuk klasifikasi merupakan ciri makroskopis kayu atau yang bisa dilihat dengan mata telanjang.

1.5 Kontribusi

Hasil penelitian ini dapat digunakan sebagai bahan pertimbangan baik bagi lembaga kehutanan maupun masyarakat umum untuk menerapkan klasifikasi kekuatan kayu berbasis pengolahan citra. Kontribusi yang diharapkan dengan adanya teknik klasifikasi kekuatan kayu yaitu dapat membantu dalam pemilihan kayu sesuai dengan peruntukannya sehingga hasil olahan semakin bagus dan tahan lama. Selain itu ke depannya diharapkan dengan metode ini dapat menemukan alternatif kayu lain untuk fungsi yang sama jika kayu utama sudah mulai langka.

Halaman ini sengaja dikosongkan

BAB 2

KAJIAN PUSTAKA

Dalam bab ini akan dibahas mengenai kajian pustaka yang menjadi dasar dalam melakukan penelitian, yang mencakup kajian penelitian terkait dan teori dasar dari penelitian ini. Sumber utama yang dijadikan rujukan kajian pustaka adalah jurnal/seminar internasional.

2.1 Kajian Penelitian Terkait

Untuk memperkaya bahan kajian, beberapa penelitian terkait dengan tema yang sama menjadi bahan referensi dalam penelitian ini. Tema-tema yang dimaksud adalah terkait dengan pengolahan citra terhadap permukaan kayu. Pada penelitian-penelitian sebelumnya, mayoritas menggunakan cacat kayu sebagai parameter utama dalam menentukan kualitas kayu. Di antaranya dengan menggunakan metode *Wavelets* dan *K-NN* untuk mengidentifikasi sekaligus mengklasifikasi cacat kayu (Çetiner, Var and Cetiner, 2016). Dengan kedua metode tersebut, mereka mampu mengklasifikasi jenis cacat yang diambil dari citra kayu menjadi tujuh kelas dengan akurasi mencapai 98%. Tujuh jenis cacat kayu tersebut yaitu *leaf*, *encased*, *dry*, *edge*, *horn*, *sound* dan *decayed*. Penelitian ini menggunakan *database* dari *Oulu University Wood Technology Laboratories* yang terdiri dari 438 citra cacat kayu berlabel.

Metode *Gray-Level Co-Occurrence Matrix* (GLCM) dipadukan dengan *PSO Trained Neural Network* juga diklaim mampu mengklasifikasikan cacat kayu menjadi 3 kelas, yaitu: *dry*, *horn* dan *sound* (Qayyum et al., 2016). Dataset dalam penelitian ini diambil dari *University of Oulu* berjumlah 90 data, dimana tiap jenis cacat kayu masing-masing berjumlah 30 data. Penelitian ini menggunakan empat fitur hasil perhitungan GLCM sebagai input, yaitu *contrast*, *correlation*, *energy* dan *homogeneity*. Hasil klasifikasi diukur menggunakan nilai akurasi sebesar 78,26% dan nilai *mean squared error* (MSE) sebesar 0,3483.

Metode GLCM juga digunakan untuk mengklasifikasi kualitas kayu kelapa berdasarkan kepadatan bundel serat (Pramunendar et al., 2013). Penelitian

ini menggunakan data 170 citra kayu kelapa yang dikumpulkan dari Pendidikan Industri Kayu (PIKA) Semarang Indonesia. Seluruh dataset tersebut dibagi menjadi tiga kelas, yaitu: kepadatan rendah (Kelas A), kepadatan sedang (Kelas B), dan kepadatan tinggi (Kelas C). Input yang digunakan sebanyak 21 fitur orde pertama dan kedua dari GLCM. Dengan menggunakan metode klasifikasi *Multi Layer Perceptron* (MLP) dan *Support Vector Machine* (SVM) masing-masing mampu memberikan akurasi terbaik sebesar 78,82% dan 77,06%.

Warna citra kayu juga digunakan sebagai parameter utama pada beberapa penelitian sebelumnya. Di antaranya dengan mengkombinasikan parameter warna dan parameter tekstur (GLCM) untuk mengidentifikasi jenis kayu (Filho et al., 2010). Data yang digunakan diambil dari *Laboratory of Wood Anatomy of the UFPR (Federal University of Parana)* sebanyak 1270 citra yang terbagi menjadi 22 jenis kayu yang berbeda. Fitur warna yang digunakan yaitu G (*green*) dari kanal RGB, S (*saturation*) dari HSV dan L (*luminance*) dari CIELUV. Sedangkan dari GLCM diambil enam fitur, yaitu: *energy*, *contrast*, *entropy*, *homogeneity*, *maximum likelihood* dan *Third Order Moment*. Akurasi yang didapatkan sebesar 80,8% dengan menggunakan algoritma MLP.

Hampir sama dengan sebelumnya, parameter warna dan GLCM juga dikombinasikan untuk mengidentifikasi empat jenis kayu keras (Asmara, Hamidi and Puspitasari, 2017). Perbedaannya untuk ekstraksi fitur warna menggunakan nilai piksel yang paling sering muncul pada setiap kanal RGB. Sedangkan ekstraksi fitur dari GLCM menghasilkan nilai *contrast*, *correlation*, *ASM*, *entropy* dan *homogeneity*. Pengambilan citra kayu diambil secara mandiri terhadap empat jenis kayu keras, yaitu: jati (*teak*), mahoni (*mahogany*), mahoni Filipina (*Philippines mahogany*) dan meranti (*shorea*). Dengan menggunakan algoritma klasifikasi *backpropagation* didapatkan akurasi sekitar 90%. Unsur warna yaitu nilai rata-rata dari tiap kanal RGB juga digunakan untuk memprediksi kepadatan kayu (Bardak and Bardak, 2017). Dengan menggunakan *fuzzy logic*, keakuratan prediksi bisa mencapai 98,17%.

Pada penelitian ini akan diklasifikasikan kekuatan kayu dengan menggabungkan fitur yang diambil dari tekstur citra (GLCM) dan nilai rata-rata tiap kanal warna RGB. Parameter GLCM menjadi pilihan karena pada penelitian-

penelitian sebelumnya sudah banyak yang menggunakan metode ini untuk mengidentifikasi tekstur kayu dan mempunyai performa yang cukup bagus. Sedangkan parameter rata-rata tiap kanal RGB terinspirasi dari penelitian untuk memprediksi kepadatan kayu (Bardak and Bardak, 2017). Karena kekuatan kayu sangat berhubungan dengan kepadatan, maka seharusnya fitur yang digunakan dalam memprediksi kepadatan kayu juga bisa digunakan untuk mengklasifikasi kekuatan kayu.

Sampai saat ini belum ada jurnal/karya tulis lain yang membahas klasifikasi kekuatan kayu dengan mengkombinasikan kedua parameter di atas. Parameter cacat kayu tidak dimasukkan dalam penelitian ini karena kayu yang dijadikan obyek penelitian disyaratkan bebas dari adanya cacat kayu. Fitur-fitur tersebut kemudian diklasifikasikan menggunakan beberapa algoritma untuk dibandingkan performanya serta ditentukan algoritma mana yang paling cocok dalam mengklasifikasi kekuatan kayu.

2.2 Teori Dasar

2.2.1 Kekuatan Kayu

Kelas kuat kayu adalah tingkat ketahanan alami suatu jenis kayu terhadap kekuatan mekanis (beban) yang terjadi pada kayu tersebut. Istilah kekuatan sering digunakan dalam arti umum untuk menyatakan semua sifat mekanik. Hal ini dapat menyebabkan kekacauan karena banyak terdapat tipe-tipe kekuatan dan sifat elastik yang berbeda-beda. Kayu yang relatif kuat sehubungan dengan satu kekuatan mungkin tingkatnya lebih rendah pada sifat yang lain apabila dibandingkan dengan spesies yang lain.

Sifat-sifat mekanik kayu yang penting diketahui kaitannya dengan kekuatan kayu, yaitu :

1. Kekuatan lengkung (MOR): menentukan beban yang dapat dipikul suatu gelagar.
2. Kekuatan tekan sejajar serat: menentukan beban yang dapat dipikul suatu tiang atau pancang yang pendek.
3. Tekanan tegak lurus serat: penting dalam rancangan sambungan-sambungan antara siku-siku kayu dalam suatu bangunan dan pada penyangga gelagar.

4. Kekuatan tarik sejajar serat: penting untuk siku bawah (busur) pada penopang kayu dan dalam rancangan sambungan antara siku-siku bangunan.
5. Kekuatan geser sejajar serat: sering menentukan kapasitas beban yang dapat dipikul oleh gelagar pendek.
6. Keuletan: ukuran banyaknya kerja yang dikeluarkan untuk memecahkan contoh uji kecil dengan pukulan.
7. Kekenyalan: diukur dengan banyaknya energi yang diserap apabila sepotong kayu dibengkokkan dalam kisaran elastisitasnya.
8. Kekerasan sisi: berhubungan dengan ketahanannya terhadap lekukan seperti untuk rantai.
9. Usaha sampai beban maksimal: ukuran energi yang diserap oleh contoh-contoh uji kecil dibengkokkan perlahan-lahan.
10. Modulus elastisitas: ukuran ketahanan terhadap pembengkokan, yaitu berhubungan langsung dengan kekakuan gelagar juga suatu faktor untuk kekuatan tiang yang panjang.
11. Modulus elastis (MOE) sejajar serat (Modulus Young): ukuran ketahanan terhadap pemanjangan atau pemendekan suatu contoh uji dibawah tarikan atau tekanan.

Di dalam Vademecum Kehutanan Indonesia (Dirjen Kehutanan, 1976), kelas kayu berdasarkan kekuatan dibagi menjadi lima kelas yang secara rinci dipaparkan pada Tabel 2.1:

Tabel 2.1 Klasifikasi Kekuatan Kayu

Kelas	Berat Jenis	Kuat Lentur (kg/cm²)	Kuat Tekan (kg/cm²)
I (Sangat Kuat)	> 0,90	> 1.100	>650
II (Kuat)	0,60 - 0,90	725 - 1.100	425 – 650
III (Sedang)	0,40 - 0,60	500 – 725	300 – 425
IV (Lemah)	0,30 - 0,40	360 – 500	215 – 300
V (Sangat lemah)	< 0,30	< 360	< 215

Ada banyak hal yang mempengaruhi kekuatan kayu, di antaranya:

1. Kerapatan

Kerapatan merupakan salah satu parameter penting untuk menentukan tingkat kekuatan kayu karena berkorelasi dengan berat jenis kayu. Berat jenis didefinisikan sebagai perbandingan kerapatan dari suatu zat terhadap kerapatan air (Sucipto, 2009).

2. Warna

Warna merupakan sifat kayu yang sangat beragam, tidak hanya antara jenis pohon yang berbeda tetapi juga diantara pohon dalam satu jenis, bahkan sering berbeda dalam potongan kayu yang sama. Kayu teras umumnya memiliki warna kayu yang lebih gelap dari pada kayu gubalnya. Kayu yang lebih tua dapat memiliki warna yang lebih gelap dari kayu yang lebih muda dari jenis kayu yang sama.

3. Tekstur

Tekstur kayu merupakan kesan permukaan kayu yang ditunjukkan oleh besar-kecilnya diameter sel-sel penyusunnya. Sehingga penentuan tekstur kayu dapat diperoleh dari identifikasi pori kayu. Pohon jika masih muda memiliki daya hisap yang sangat kuat terhadap air, tetapi jika pohon tersebut telah tua, biasanya kekuatan hisap terhadap air sudah sangat berkurang, dan pori-pori kayu tersebut telah mengecil. Secara umum semakin halus tekstur dari kayu dapat dipastikan bahwa pohonnya semakin tua, demikian juga sebaliknya.

4. Arah serat

Arah serat dapat ditentukan oleh alur-alur yang terdapat pada permukaan kayu. Kayu dikatakan memiliki serat lurus (*straight grain*) jika arah umum dari sel-sel panjang sejajar dengan sumbu batang. Kayu berserat lurus merupakan kayu yang bagus untuk konstruksi dan sambungan. Jika arah umum dari sel-sel panjang tadi menyimpang atau membentuk sudut dengan sumbu batang pohon maka disebut serat miring (*cross grain*). Serat miring dibagi sebagai berikut :

- Serat berpadu : bila sebatang kayu mempunyai arah serat miring ke kanan atau ke kiri terhadap sumbu batang. Kayu dengan serat ini masih bisa digunakan untuk konstruksi.

- Serat berombak/bergelombang: kayu ini tidak begitu bagus untuk konstruksi, karena kayu akan mudah patah dikarenakan serat yang tidak saling berhubungan.
- Serat terpilin: apabila serat dari batang membuat gambar seakan-akan mengelilingi sumbunya (puntir).
- Serat diagonal: serat yang terdapat pada sepotong kayu atau papan yang membentuk suatu sudut. Serat ini disebabkan oleh perlakuan manusia atau cara penggergajian. Sedangkan arah serat yang lain (terpadu, berombak, terpilin) disebabkan karena faktor lingkungan.

(Mandang and Pandit, 1997)

Kekuatan kayu sangat erat kaitannya dengan berat jenis. Semakin besar berat jenis kayu maka semakin kuat kayu tersebut. Hubungan antara sifat-sifat mekanik dan berat jenis dapat dilihat pada Tabel 2.2 berikut :

Tabel 2.2 Hubungan Antara Sifat-Sifat dan Berat Jenis Kadar Air 12%

Sifat	Kekuatan yang diperkirakan pada berat jenis terpilih			
	0,30	0,40	0,50	0,60
Lengkungan				
MOR (psi)	5.706	8.175	10.806	13.571
MOE (106 psi)	0,84	1,12	1,40	1,68
Tekanan sejajar serat				
Tekan maksimum(psi)	3.660	4.880	6.100	7320
MOE (106 psi)	1,01	1,35	1,69	2,03
Tegangan sejajar serat				
Tegangan proporsi (psi)	308	589	973	1.467
Kekerasan sisi	251	480	973	1.94

Sumber : (Haygreen and Bowyer, 1993)

Tabel 2.2 di atas menunjukkan sejumlah kekuatan dan berat jenis yang ditetapkan oleh laboratorium hasil hutan Amerika Serikat dengan menguji 160 jenis kayu. Dapat dilihat bahwa sifat-sifat seperti MOE dalam lengkungan dan keteguhan tekan maksimum sejajar serat naik secara linear dengan berat jenis.

Hubungan untuk sifat-sifat yang lain adalah fungsi pangkat. Jadi sebagian sifat-sifat naik dengan berat jenis jauh lebih cepat daripada yang lain

Berdasarkan SNI 03-6847-2002 (Badan Standarisasi Nasional, 2002), untuk menguji berat jenis kayu, benda uji harus memenuhi syarat sebagai berikut:

1. Mewakili benda yang diuji, dengan ukuran (50x50x50) mm;
2. Permukaanya bersih, bebas dari serat, bebas mata kayu dan kantung damar atau cairan lain;
3. Ukurannya sesuai dengan wadah tempat pencelupan, tidak terlalu besar dan tidak pula terlalu sempit yang dapat mempengaruhi hasil pengukuran.

Berdasarkan referensi buku dan penelitian di bidang kehutanan, berat jenis dan kelas kuat dari 7 (tujuh) kayu yang digunakan sebagai obyek penelitian tersaji pada Tabel 2.3.

Tabel 2.3 Kelas Kuat Kayu Obyek Penelitian

No	Jenis Kayu	Rata-rata Berat Jenis	Kelas Kuat	Sumber
1	Akasia	0,63	II-III	(Purwanto, 2012)
2	Jati	0,67	II	(Martawijaya et al., 2005)
3	Mahoni	0,62	II-III	(Martawijaya et al., 2005)
4	Sengon laut	0,33	IV-V	(Martawijaya et al., 1989)
5	Sengon tekek	0,33	IV-V	(Martawijaya et al., 1989)
6	Trembesi	0,44	III	(Hidayati and Siagian, 2012)
7	Waru	0,54	III	(Suprpti, Djarwanto and Hudiansyah, 2004)

Nilai berat jenis ditentukan dari nilai kerapatan kayu (ρ_{kayu}) yang dihitung dengan menggunakan Persamaan 2.1.

$$BJ = \frac{\rho_{kayu}}{\rho_{H_2O}} \quad (2.1)$$

Kerapatan air (ρ_{H_2O}) adalah 1 g/ml sedangkan kerapatan kayu (ρ_{kayu}) dihitung dengan cara menimbang massa kering udara (m) dan mengukur volume (V) dari kayu uji. Kemudian dihitung menggunakan Persamaan 2.2.

$$\rho_{kayu} = \frac{m}{V} \quad (2.2)$$

2.2.2 Ekstraksi Fitur

Ekstraksi fitur adalah proses pengambilan ciri sebuah objek yang dapat menggambarkan karakteristik khusus dari objek tersebut. Fitur dibedakan menjadi dua yaitu: 1) fitur alami yang merupakan fitur bawaan dari gambar, misalnya kecerahan dan tepi objek. 2) Fitur buatan yaitu fitur yang diperoleh dengan operasi tertentu pada gambar, misalnya histogram tingkat keabuan. Fitur dalam citra yang umumnya diekstrak antara lain:

1. Ekstraksi Fitur Bentuk

Bentuk dari suatu objek adalah karakter konfigurasi permukaan yang diwakili oleh garis dan kontur. Untuk membedakan bentuk objek satu dengan objek lainnya, dapat menggunakan parameter yang disebut dengan *eccentricity*. *Eccentricity* merupakan nilai perbandingan antara jarak *foci ellips minor* dengan *foci ellips mayor* suatu objek. *Eccentricity* memiliki rentang nilai antara 0 hingga 1. Objek yang berbentuk memanjang/mendekati bentuk garis lurus, nilai *eccentricity*-nya akan mendekati angka 1, sedangkan objek yang berbentuk bulat/lingkaran, nilai *eccentricity*-nya akan mendekati angka 0.

Parameter lainnya yang dapat digunakan untuk membedakan bentuk suatu objek yaitu *metric*. *Metric* merupakan nilai perbandingan antara luas dan keliling objek. *Metric* memiliki rentang nilai antara 0 hingga 1. Objek yang berbentuk memanjang/mendekati bentuk garis lurus, nilai *metric*-nya mendekati angka 0, sedangkan objek yang berbentuk bulat/lingkaran, nilai *metric*-nya mendekati angka 1.

2. Ekstraksi Fitur Ukuran

Untuk membedakan ukuran objek satu dengan objek lainnya dapat menggunakan parameter luas dan keliling. Luas merupakan banyaknya piksel yang menyusun suatu objek. Sedangkan keliling merupakan banyaknya piksel yang mengelilingi suatu objek.

3. Ekstraksi Fitur Geometri

Fitur geometri merupakan ciri yang didasarkan pada hubungan antara dua buah titik, garis, atau bidang dalam citra digital, di antaranya adalah jarak dan sudut. Jarak antara dua buah titik (dengan satuan piksel) dapat ditentukan menggunakan persamaan *euclidean*, *minkowski*, *manhattan*, dll. Jarak dengan satuan piksel tersebut dapat dikonversi menjadi satuan panjang seperti milimeter, centimeter, meter, dll dengan cara membaginya dengan resolusi spasial. Sedangkan sudut antara dua buah garis dapat ditentukan dengan perhitungan trigonometri maupun dengan analisis vektor.

4. Ekstraksi Fitur Tekstur

Untuk membedakan tekstur objek satu dengan objek lainnya dapat menggunakan fitur statistik orde pertama atau fitur statistik orde dua. Fitur orde pertama didasarkan pada karakteristik histogram citra. Fitur orde pertama umumnya digunakan untuk membedakan tekstur makrostruktur (perulangan pola lokal secara periodik). Fitur orde pertama antara lain: *mean*, *variance*, *skewness*, *kurtosis*, dan *entropy*. Sedangkan fitur orde dua didasarkan pada probabilitas hubungan ketetanggaan antara dua piksel pada jarak dan orientasi sudut tertentu. Ciri orde dua umumnya digunakan untuk membedakan tekstur mikrostruktur (pola lokal dan perulangan tidak begitu jelas). Ciri orde dua antara lain: *Angular Second Moment*, *Contrast*, *Correlation*, *Variance*, *Inverse Different Moment*, dan *Entropy*.

5. Ekstraksi Fitur Warna

Pada metode ini ciri pembeda adalah warna. Fitur warna bisa didapatkan dari distribusi warna dan warna dominan pada citra. Biasanya ekstraksi fitur ini digunakan pada citra yang memiliki komposisi warna RGB (*red*, *green*, *blue*). Dari nilai RGB tersebut bisa dikembangkan untuk mendapat nilai *hue* yang merupakan representasi dari cahaya tampak. Serta nilai *saturation* dan *value* yang merupakan tingkat kecerahan dari suatu warna.

Dalam penelitian ini, digunakan dua metode dalam mengekstraksi fitur citra kayu, yaitu: ekstraksi fitur warna RGB yang digunakan untuk mengidentifikasi kekuatan kayu berdasarkan warnanya dan GLCM (*Gray Level Co-Occurrence Matrix*) yang fokus pada ekstraksi fitur tekstur citra kayu.

2.2.2.1 Kanal Citra RGB


Pengolahan citra digital merujuk pada pemrosesan gambar dua dimensi menggunakan komputer. Secara umum, proses digitalisasi pada citra digital dibagi menjadi tiga proses yaitu akuisisi citra, sampling dan kuantisasi. Berdasarkan jenis warnanya, citra digital dapat dibedakan menjadi tiga jenis yaitu citra RGB, *grayscale*, dan biner. Citra RGB (*Red, Green, Blue*) merupakan citra yang nilai intensitas pikselnya tersusun oleh tiga kanal warna yaitu merah, hijau, dan biru. Citra *grayscale* adalah citra yang nilai intensitas pikselnya berdasarkan derajat keabuan. Sedangkan citra biner adalah citra yang hanya memiliki dua nilai intensitas yaitu 0 (hitam) dan 1 (putih).

Hampir setiap pengolahan citra yang berbasis warna, khususnya RGB, perlu dilakukan pemisahan kanal warna yang ada pada citra tersebut. Masing-masing kanal warna memiliki nilai intensitas piksel dengan kedalaman bit sebesar 8-bit yang artinya memiliki variasi warna sebanyak 2^8 derajat warna (0 s.d 255). Pada kanal merah, warna merah sempurna direpresentasikan dengan nilai 255 dan hitam sempurna dengan nilai 0. Pada kanal hijau, warna hijau sempurna direpresentasikan dengan nilai 255 dan hitam sempurna dengan nilai 0. Begitu juga pada kanal biru, warna biru sempurna direpresentasikan dengan nilai 255 dan hitam sempurna dengan nilai 0.

Setiap piksel pada citra RGB, memiliki intensitas warna yang merupakan kombinasi dari tiga nilai intensitas pada kanal R, G, dan B. Sebagai contoh, suatu piksel yang memiliki nilai intensitas warna sebesar 255 pada kanal merah, 255 pada kanal hijau, dan 0 pada kanal biru akan menghasilkan warna kuning. Pada contoh lain, suatu piksel yang memiliki nilai intensitas warna sebesar 255 pada kanal merah, 102 pada kanal hijau, dan 0 pada kanal biru akan menghasilkan warna orange. Banyaknya kombinasi warna piksel yang mungkin pada citra RGB truecolor 24-bit adalah sebanyak $256 \times 256 \times 256 = 16.777.216$.

Tiap kanal tersebut kemudian dijadikan histogram untuk mendapatkan karakteristik dari suatu citra. Histogram citra merupakan diagram yang menggambarkan distribusi frekuensi nilai intensitas warna dalam suatu citra seperti tampak pada Gambar 2.1. Tujuannya adalah untuk menandai bagian yang

menjadi detail citra, serta untuk memperbaiki detail dari citra yang kabur, yang terjadi karena error atau adanya efek dari proses akuisisi citra.




Gambar 2.1 Histogram Warna RGB

2.2.2.2 Gray Level Co-Occurrence Matrix (GLCM)

GLCM merupakan metode statistik dimana dalam perhitungannya menggunakan distribusi derajat keabuan (Xie et al., 2010). Fitur dari metode ini diperoleh dari nilai piksel matrik, yang mempunyai nilai tertentu dan membentuk suatu sudut pola. Untuk sudut yang digunakan dalam GLCM adalah 0° , 45° , 90° dan 135° . Ekstraksi ciri statistik terbagi menjadi dua, yaitu ekstraksi fitur statistik orde pertama dan orde kedua. Di antara fitur yang dapat dihitung dari orde pertama adalah: *mean*, *skewness*, dan *kurtosis*. Ekstraksi orde pertama merupakan pengambilan ciri didasarkan pada karakteristik probabilitas kemunculan nilai derajat keabuan piksel pada suatu citra (Maharsi, Halomoan and Atmaja, 2015). Fitur orde pertama kadang tidak bisa digunakan untuk mengenali perbedaan antar citra sehingga diperlukan statistik orde kedua. Ekstraksi ini didasarkan dari menghitung probabilitas hubungan ketetanggaan antara dua piksel pada jarak dan sudut tertentu seperti diilustrasikan pada Gambar 2.2. Jarak dinyatakan dalam piksel dan orientasi dinyatakan dalam derajat. Orientasi dibentuk dalam empat arah sudut dengan interval sudut 45° , yaitu 0° , 45° , 90° , dan 135° . Sedangkan jarak antar piksel biasanya ditetapkan sebesar 1 piksel, 2 piksel, 3 piksel dan

seterusnya. Pendekatan ini bekerja dengan membentuk sebuah matriks kookurensi dari data citra, dilanjutkan dengan menentukan ciri sebagai fungsi dari matriks tersebut.



Gambar 2.2 Alur Ekstraksi Fitur pada GLCM

Dalam penelitian ini, akan digunakan jarak (*distance*) 1 piksel dan membandingkan hasil ekstraksi fitur dari semua sudut GLCM. Metode ini menghasilkan 6 fitur utama yaitu:

1. Angular Second Moment (ASM)

Mengukur keseragaman level keabuan citra. Semakin seragam nilai piksel, nilai ASM semakin besar. Fungsi untuk mencari ASM didefinisikan pada Persamaan 2.3.

$$ASM = \sum_i \sum_j P^2[i, j] \quad (2.3)$$

2. Contrast

Mengukur variasi persebaran elemen pada matriks citra. Nilai contrast yang besar menandakan bahwa ada perbedaan intensitas yang besar pada GLCM. Fungsi mencari nilai contrast didefinisikan pada Persamaan 2.4.

$$Contrast = \sum_i \sum_j (i - j)^2 P[i, j] \quad (2.4)$$

3. Correlation

Menyatakan ukuran ketergantungan linier antar nilai derajat keabuan dalam matriks. Fungsi untuk mencari correlation didefinisikan pada Persamaan 2.5.

$$Correlation = \frac{\sum_i \sum_j i j P[i, j] - \mu_i \mu_j}{\sigma_i \sigma_j} \quad (2.5)$$

4. Variance

Mengukur penyebaran derajat nilai keabuan terhadap nilai rata-rata. Fungsi dinyatakan dalam Persamaan 2.6.

$$Variance = \sum_i \sum_j (i - \mu)^2 P[i, j] \quad (2.6)$$

5. Inverse Difference Moment (IDM)

Mengukur homogenitas derajat nilai keabuan citra. Fungsi dinyatakan dalam Persamaan 2.7.

$$Contrast = \sum_i \sum_j \frac{P[i, j]}{1 + |i - j|} \quad (2.7)$$

6. Entropy

Menyatakan ketidakaturan derajat nilai keabuan dari matriks. Fungsi dinyatakan dalam Persamaan 2.8.

$$Entropy = - \sum_i \sum_j P[i, j] \log P[i, j] \quad (2.8)$$

Dimana (i,j) menyatakan nilai pada baris (i) dan kolom (j), P adalah probabilitas pada matrik GLCM, μ adalah *mean* yang dinyatakan dalam Persamaan 2.9 dan 2.10. Sedangkan σ adalah *standard deviation* yang dinyatakan dalam fungsi pada Persamaan 2.11 dan 2.12.

$$\mu_i = \sum_i i \sum_j P[i, j] \quad (2.9)$$

$$\mu_j = \sum_i \sum_j j P[i, j] \quad (2.10)$$

$$\sigma_i = \sqrt{\sum_i \sum_j (i - \mu_i)^2 P[i, j]} \quad (2.11)$$

$$\sigma_j = \sqrt{\sum_i \sum_j (j - \mu_j)^2 P[i, j]} \quad (2.12)$$

Selain enam fitur di atas, juga ada beberapa fitur turunan yang dihasilkan dari matriks GLCM, yaitu: *Sum Average*, *Sum Variance*, *Difference Variance*, *Sum Entropy*, *Difference Entropy*, *Measure of Correlation I* dan *Measure of Correlation II*.

2.2.3 Seleksi Fitur

Seleksi fitur menjadi bagian yang tak terpisahkan khususnya pada bidang penelitian yang menggunakan *machine learning*. Seleksi fitur merupakan suatu proses menghilangkan fitur yang berlebihan dan tidak relevan dengan dataset yang digunakan. Manfaat utama dari seleksi fitur adalah mempercepat proses klasifikasi, serta meningkatkan akurasi (Doraisamy et al., 2008). Ada dua titik berat seleksi fitur dengan pendekatan *machine learning* yaitu memilih fitur yang akan digunakan dan menjelaskan secara konsep bagaimana mengkombinasikan fitur-fitur tersebut untuk menghasilkan konsep induksi yang benar atau hasil yang sesuai.

Secara umum, seleksi fitur dapat dibagi menjadi tiga pendekatan:

1. *Filters Selectors*

Metode ini mengevaluasi setiap fitur secara bebas, kemudian memberikan peringkat pada setiap fitur dan mengambil fitur yang unggul (Guyon and Elisseeff, 2003).

2. *Wrappers Selectors*

Metode ini bekerja dengan membagi semua fitur menjadi beberapa subset. Kemudian setiap subset dievaluasi menggunakan algoritma pengklasifikasi

tertentu hingga ditemukan subset dengan kinerja yang paling baik. Jadi kinerja *wrappers* bergantung pada algoritma pengklasifikasi yang dipilih, bahkan *wrappers* bisa lebih dapat diandalkan karena tingkat akurasi dipengaruhi oleh algoritma apa yang dipilih (Novakovic, 2010).

3. *Embedded Selectors*

Metode ini melakukan seleksi fitur selama proses *learning*, seperti yang terjadi pada jaringan syaraf tiruan dan *deep learning*.

Penelitian ini akan menggunakan algoritma *Recursive Feature Elimination* (RFE) dalam menyeleksi fitur. *Recursive Feature Elimination* (RFE) diperkenalkan pertama kali untuk mengklasifikasi gen kanker (Guyon et al., 2002). Pada setiap iterasi, metode ini memberikan bobot ke fitur melalui atribut *coefficients* dan *feature_importance* yang terdapat pada beberapa algoritma klasifikasi, seperti: *Linear Discriminant Analysis* (LDA), *Logistic Regression* (LR), *Random Forest* dan *Decision Tree*. Kemudian fitur yang paling rendah bobotnya dipangkas dari dataset. Prosedur tersebut dilakukan secara berulang hingga dataset terkecil agar diketahui jumlah fitur yang optimal.

Salah satu kekurangan metode RFE adalah sifatnya yang sangat sensitif terhadap data *training*, sehingga menghasilkan bobot fitur dengan variasi yang tinggi. *Recursive Feature Elimination Cross Validation* (RFECV) mengatasi permasalahan tersebut dengan penambahan fitur *cross validation*. RFECV memberikan kesempatan pada seluruh dataset untuk menjadi *testing* set, sehingga menjadi lebih stabil dan handal dalam pembobotan fitur (Zhang et al., 2013).


2.2.4 Klasifikasi

Penelitian ini akan menggunakan algoritma *multi class* atau *multinomial classification* karena data diklasifikasikan hanya ke dalam salah satu dari tiga atau banyak kelas (Pedregosa et al., 2011). Di antara algoritma *multi class* yang ada, penelitian ini hanya akan menggunakan 5 (lima) algoritma:

2.2.4.1 *K-Nearest Neighbours (KNN)*

KNN merupakan algoritma yang berfungsi untuk melakukan klasifikasi suatu data berdasarkan data pembelajaran berdasarkan *k* tetangga terdekatnya

(*nearest neighbors*). Dengan k merupakan banyaknya tetangga terdekat. Algoritma ini diilustrasikan seperti pada Gambar 2.3.



Gambar 2.3 Ilustrasi Algoritma KNN

Ada beberapa metode untuk menghitung jarak terdekat, di antaranya yang paling populer :

a. *Euclidean Distance*

Metode ini mencari jarak antara dua titik dalam ruang dua dimensi. Ide metode ini diambil dari rumus *Pythagoras*. Untuk menghitung jarak terdekat (d), metode ini menggunakan Persamaan 2.13.

$$d = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.13)$$

b. *Manhattan Distance*

Metode ini menghitung jarak hanya dengan menjumlahkan semua selisih dari jarak x_i dan y_i . Proses perhitungan metode ini dapat dilihat di Persamaan 2.14.

$$d = \sum_{i=1}^n |x_i - y_i| \quad (2.14)$$

c. *Minkowsky Distance*

Metode ini mengukur jarak antar 2 titik pada ruang vektor normal yang merupakan generalisasi dari *euclidean distance* dan *manhattan distance*. Persamaan 2.15 merupakan proses perhitungan dari metode ini.

$$d = (\sum_{i=1}^n |x_i - y_i|^r)^{1/r} \quad (2.15)$$

Ide dari *minkowsky distance* diambil dari konsep aljabar dengan nilai r bukan 1 dan 2. Karena jika $r=1$ maka akan terbentuk *manhattan distance*, sedangkan jika $r = 2$ terbentuk *euclidean distance*.

2.2.4.2 Linear Discriminant Analysis (LDA)

LDA pertama kali dikembangkan oleh R.A Fisher pada tahun 1936. Konsep awal dari klasifikasi LDA adalah mencari kombinasi linier variabel (ciri) yang dapat dipisahkan ke dalam dua kelas dengan baik. Tujuan LDA adalah memproyeksikan fitur-fitur ke dalam ruang dimensi yang lebih kecil sehingga semua pola dapat dipisahkan semaksimal mungkin. LDA akan memaksimalkan penyebaran data-data input pada kelas yang berbeda, sekaligus juga meminimalkan penyebaran input pada kelas yang sama. Dalam LDA, variasi data disebut dengan *scatter* atau diagram sebar.

Untuk dapat mencapai tujuannya, setidaknya algoritma ini membutuhkan tiga langkah. Langkah pertama menghitung jarak rata-rata antar kelas atau *scatter between-class* (S_b). Fungsi ini dihitung menggunakan Persamaan 2.16.

$$S_b = \sum_i P_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (2.16)$$

Dimana μ adalah *mean* dan P adalah probabilitas. Langkah kedua adalah menghitung jarak antara *mean* dan sampel masing-masing kelas atau *scatter within class* (S_w) menggunakan Persamaan 2.17.

$$S_w = \sum_i^n (P_i - 1) S_i = \sum_i^n \sum_j^{P_i} (\mu_{i,j} - \mu_i)(\mu_{i,j} - \mu_i)^T \quad (2.17)$$


Langkah terakhir adalah menentukan proyeksi optimal yang memaksimalkan S_b dan meminimalkan S_w . Proyeksi (P) yang disebut criteria *Fisher* dirumuskan dalam Persamaan 2.18.

$$P_{lda} = \underset{P}{argmax} \frac{|P^T S_b P|}{|P^T S_w P|} \quad (2.18)$$

2.2.4.3 Decision Tree

Decision tree adalah salah satu metode klasifikasi yang paling populer, karena mudah untuk diinterpretasi oleh manusia. Konsep metode ini adalah mengubah data menjadi pohon dan aturan-aturan keputusan. Manfaat utama dari penggunaan *decision tree* adalah kemampuannya untuk mengurai proses pengambilan keputusan yang kompleks menjadi lebih sederhana, sehingga pengambil keputusan akan lebih menginterpretasikan solusi dari permasalahan.

Metode ini dibentuk dari tiga tipe simpul: simpul akar, simpul perantara dan simpul *leaf*. Simpul akar adalah titik awal dari suatu *decision tree*. Setiap simpul perantara berhubungan dengan suatu pertanyaan atau pengujian. Sedangkan simpul *leaf* memuat suatu keputusan akhir atau output dari *decision tree*. Ilustrasi algoritma *Decision Tree* bisa dilihat pada Gambar 2.4.



Gambar 2.4 Ilustrasi Algoritma *Decision Tree*

Decision Tree pertama kali diperkenalkan oleh J.R. Quinlan dengan menggunakan algoritma inti yang disebut ID3 yang merupakan kependekan dari *Iterative Dichotomiser* (Quinlan, 1986). ID3 menggunakan *entropy* dan

information gain untuk membangun sebuah pohon keputusan. *Entropy* pada *Decision Tree* bisa dihitung menggunakan Persamaan 2.19.


$$Entropy = \sum_{i=1} -p_i \log_2 p_i \quad (2.19)$$

dimana p adalah probabilitas. Nilai *entropy* tersebut kemudian digunakan untuk menghitung *information gain* dengan menggunakan Persamaan 2.20.

$$InfoGain = Entropy(S_1) - Entropy(S_2) \quad (2.20)$$

Pada setiap langkah dalam membangun ID3, *decision tree* menggunakan nilai *information gain* terbesar untuk memilih kandidat terbaik sebagai simpul akar. Proses ini dijalankan secara rekursif pada cabang-cabang simpul sampai semua data terklasifikasikan.

2.2.4.4 Random Forest



Gambar 2.5 Ilustrasi Algoritma *Random Forest*


Random Forest merupakan sebuah metode *ensemble* (gabungan) yang terdiri dari beberapa *decision tree* sebagai *classifier* dan serupa dengan teknik *bagging* (Breiman, 2001). *Bagging* adalah kependekan dari *bootstrap aggregating*, dimana teknik ini menggunakan banyak subdataset yang *disampling* (*bootstrap*) untuk dijadikan data pelatihan. Dalam kasus *random*

forest, setiap subdataset akan menjadi satu pohon keputusan. Selanjutnya dijalankan proses *aggregating* yaitu menggabungkan banyak nilai dugaan menjadi satu nilai (Breiman, 1996). Ilustrasi Algoritma *Random Forest* bisa dilihat pada Gambar 2.5.

Output yang dihasilkan dari proses klasifikasi ini diambil dari kelas terbanyak yang dihasilkan oleh pohon-pohon keputusan. Dengan melakukan *majority-vote* (suara terbanyak) pada pohon-pohon keputusan yang tersedia membuat akurasi dari *Random Forest* meningkat. Breiman dalam penelitiannya menunjukkan kelebihan *random forest* yang dapat menghasilkan error yang lebih rendah, dapat memberikan hasil yang bagus dalam klasifikasi dan dapat mengatasi data training dalam jumlah sangat besar secara efisien serta merupakan metode yang efektif untuk mengestimasi *missing data*.


2.2.4.5 Support Vector Machine (SVM) Classification

Support Vector Machine (SVM) pertama kali diperkenalkan oleh Vapnik untuk menyelesaikan permasalahan klasifikasi, regresi dan ranking dalam *supervised learning*. Kelebihan SVM dibandingkan metode yang lain adalah memiliki landasan teori yang jelas dan bisa dianalisis sehingga tidak bersifat *blackbox*, dapat diselesaikan dengan metode sekuensial, serta mudah diimplementasikan. Akurasi pada model yang dilatih menggunakan SVM sangat bergantung pada fungsi kernel dan parameter yang ditentukan (Siagian, 2011).



Gambar 2.6 Cara kerja SVM (Nugroho, 2008)

Berdasarkan karakteristiknya, SVM dibagi menjadi dua, yaitu SVM linier dan non-linier. Dalam proses training, SVM linier mencari *hyperplane* terbaik yang berfungsi sebagai pemisah antara dua kelas. Caranya yaitu dengan mengukur jarak *hyperplane* tersebut dengan data terdekat dari masing-masing kelas dan mencari titik maksimalnya. Sample data *training* set terdekat inilah yang disebut dengan *support vector*. Garis solid pada gambar 2.6 di atas menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua kelas, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM. Adapun SVM Non-Linier menerapkan fungsi dari kernel trick serta memetakan data ke ruang vector yang berdimensi lebih tinggi. Ada beberapa jenis kernel yang populer yaitu *polynomial*, *gaussian* dan *sigmoid* (Nugroho, 2008).



Gambar 2.7 Cara kerja OAOSVM dan OAASVM

Awalnya SVM hanya digunakan untuk klasifikasi dua kelas saja, namun untuk menyelesaikan berbagai permasalahan di dunia nyata dikembangkan multi-class SVM. Di antaranya One-Against-One (OAOSVM) yaitu melalui pendekatan yang secara langsung menggunakan semua data dari semua kelas dalam satu formulasi persoalan optimisasi. Sedangkan One-Against-All (OAASVM) yaitu dengan pendekatan menemukan dan menggabung beberapa fungsi pemisah persoalan klasifikasi dua kelas untuk menyelesaikan persoalan klasifikasi multi kelas (Hsu and Lin, 2002). Perbedaan cara kerja OAOSVM dan OAASVM diilustrasikan pada Gambar 2.7.


2.2.5 Evaluasi Model

Dalam membandingkan kelima algoritma klasifikasi yaitu LDA, KNN, CART, RF dan SVM, akan digunakan metode *Cross Validation* atau bisa disebut estimasi rotasi. *Cross-validation* (CV) adalah metode statistik yang dapat digunakan untuk mengevaluasi kinerja model atau algoritma dimana data dipisahkan menjadi dua subset yaitu data proses pembelajaran dan data validasi / evaluasi. Model atau algoritma dilatih oleh subset pembelajaran dan divalidasi oleh subset validasi. Salah satu metode *Cross Validation* yang populer adalah K-Fold. Dalam Algoritma K-Fold, dataset *training* dibagi menjadi sub dataset yang lebih kecil berjumlah K -buah. Kemudian CV akan melakukan iterasi sebanyak K kali. Dalam setiap iterasi, secara rotasi, satu sub dataset akan digunakan sebagai validasi, dan sisanya yaitu berjumlah $K-1$ akan digunakan sebagai pembelajaran. Untuk lebih jelasnya, bisa dilihat ilustrasi 10-Fold pada Gambar 2.8 di bawah ini.

[illegible]

Gambar 2.8 Ilustrasi 10-Fold Cross Validation

10-Fold CV adalah salah satu K-Fold CV yang direkomendasikan untuk pemilihan model terbaik karena cenderung memberikan estimasi akurasi yang minim bias dibandingkan dengan metode *Cross Validation* yang lain seperti *leave-one-out CV* dan *bootstrap*. Untuk lebih mudah dalam membandingkan performa masing-masing algoritma klasifikasi, perbandingan akan disajikan dalam bentuk *Box and Whisker Plots* atau lebih sering disebut box-plot. Seperti namanya, *Box and Whisker*, bentuknya terdiri dari *box* (kotak) dan *whisker*. Pada Gambar 2.9, *box* adalah kotak berwarna hijau dan *whisker* adalah garis berwarna biru.




Gambar 2.9 *Box and Whisker Plot*

Box-plot merupakan penyajian ringkasan distribusi sampel secara grafis yang bisa menggambarkan bentuk distribusi data (*skewness*), ukuran tendensi sentral dan ukuran penyebaran (keragaman) data pengamatan. Terdapat 5 (lima) ukuran statistik yang bisa kita baca dari boxplot, yaitu: nilai minimum, Q1 (kuartil pertama), Q2 (median), Q3 (kuartil ketiga) dan nilai maksimum. Selain itu, box-plot juga dapat menunjukkan ada tidaknya nilai *outlier* dan nilai ekstrim dari data pengamatan.

Bagian utama boxplot adalah kotak berbentuk persegi (*box*) yang menyajikan *interquartile range* (IQR), dimana 50 % dari nilai data pengamatan berada di dalamnya. Garis bawah kotak merupakan nilai Q1, garis tengah kotak merupakan Q2 (median) dan garis atas kotak merupakan nilai Q3. Garis yang

merupakan perpanjangan dari kotak baik arah ke atas maupun ke bawah disebut *whisker*. *Whisker* bawah menunjukkan nilai yang lebih rendah dari kumpulan data yang berada dalam IQR. Sedangkan *whisker* ke arah atas menunjukkan nilai yang lebih besar. Panjang *whisker* sekitar $1.5 \times \text{IQR}$, nilai yang berada di atas atau di bawah *whisker* dinamakan nilai *outlier* atau ekstrim. Detail dari box-plot beserta batas-batasnya bisa dilihat pada Gambar 2.10.



Gambar 2.10 Penentuan Batas-Batas Box-plot

Dalam metode klasifikasi, evaluasi model yang paling sering digunakan adalah *accuracy*, *precision* dan *recall*. *Accuracy* didefinisikan sebagai tingkat kedekatan antara nilai prediksi dengan nilai aktual. *Precision* adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan oleh sistem. Sedangkan *recall* adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi. Untuk mempermudah perhitungan *accuracy*, *precision* dan *recall*, bisa dibuat sebuah *confusion matrix* seperti pada Gambar 2.11.

		Nilai sebenarnya	
		TRUE	FALSE
Nilai prediksi	TRUE	TP (True Positive) <i>Corect result</i>	FP (False Positive) <i>Unexpected result</i>
	FALSE	FN (False Negative) <i>Missing result</i>	TN (True Negative) <i>Corect absence of result</i>

Gambar 2.11 *Confusion Matrix*

Dari Gambar 2.11, *accuracy*, *precision* dan *recall* masing-masing bisa dihitung menggunakan Persamaan 2.21, Persamaan 2.22 dan Persamaan 2.23.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.21)$$

$$precision = \frac{TP}{TP + FP} \quad (2.22)$$

$$recall = \frac{TP}{TP + FN} \quad (2.23)$$

Dimana:

TP (*True Positive*) : jumlah data positif yang terklasifikasi dengan benar.

TN (*True Negative*) : jumlah data negatif yang terklasifikasi dengan benar.

FN (*False Negative*) : jumlah data negatif namun terklasifikasi salah.

FP (*False Positive*) : jumlah data positif namun terklasifikasi salah.

Selain evaluasi model di atas, penelitian ini juga menggunakan pengukuran *F1-score* yang salah satu fungsinya adalah untuk menghitung keseimbangan antara *precision* dan *recall*. Fungsi untuk menghitung *F1-score* terdapat dalam Persamaan 2.24.

$$F1 = 2 \times \frac{precision * recall}{precision + recall} \quad (2.24)$$


Secara umum, *confusion matrix* hanya menyajikan informasi dalam bentuk angka. Jika ingin menampilkan performa algoritma klasifikasi dalam bentuk grafik maka dapat menggunakan *Receiver Operating Characteristic* (ROC). Kurva ROC dibuat berdasarkan nilai perhitungan dari *confusion matrix*, dimana sumbu y adalah nilai *True Positive Rate* (TPR), sedangkan sumbu x

adalah nilai *False Positive Rate* (FPR). Cara membentuknya yaitu dengan mengubah parameter-parameter yang dapat *dituning* dari algoritma klasifikasi sehingga membuat beberapa *confusion matrix*. Dari *confusion matrix* itulah diambil nilai TPR dan FPR dengan menggunakan Persamaan 2.25 dan Persamaan 2.26 di bawah ini.

$$TPR = \frac{TP}{TP + FN} \quad (2.25)$$

$$FPR = \frac{FP}{FP + TN} \quad (2.26)$$

Untuk menentukan sejauh mana performa yang digambarkan kurva ROC bisa melihat nilai *Area Under Curve* (AUC). AUC memberikan gambaran tentang keseluruhan pengukuran atas kesesuaian dari model yang digunakan. Semakin tinggi nilai AUC yaitu mendekati angka 1, maka model akan semakin bagus dalam memisahkan data antar kelas. Contoh kurva AUC - ROC bisa dilihat dalam gambar 2.12.



Gambar 2.12 Kurva ROC (Pedregosa et al., 2011)


Gambar 2.12 di atas menunjukkan kurva ROC untuk klasifikasi *multi-class*. Setiap kelas akan dibuat kurva ROC dan dihitung nilai AUC (*area under curve*). Performa klasifikasi secara keseluruhan bisa dilihat pada nilai AUC *micro-average* yang merupakan nilai rata-rata dari seluruh kelas.

Halaman ini sengaja dikosongkan

BAB 3

METODE PENELITIAN

Dalam bab ini, akan dipaparkan metode dalam mengklasifikasi kelas kuat kayu berdasarkan warna dan tekstur citra. Metode terdiri dari uji kekuatan kayu berdasarkan berat jenis, pengambilan citra, *pre-procesing* yang mencakup proses *cropping* serta konversi gambar ke citra RGB dan *grayscale*, ekstraksi fitur yang berbasis histogram kanal RGB dan GLCM, seleksi fitur menggunakan algoritma *Recursive Feature Elimination Cross Validation* (RFECV), klasifikasi menggunakan lima algoritma dan evaluasi model. Secara umum, alur penelitian tersaji dalam Gambar 3.1.



Gambar 3.1 Diagram Alir Klasifikasi Kekuatan Kayu

3.1 Uji Kekuatan Kayu

Langkah pertama yang harus dilakukan dalam penelitian ini adalah menguji kekuatan kayu berdasarkan berat jenisnya. Hasil dari pengukuran ini, nantinya akan menjadi label dalam proses klasifikasi. Obyek penelitian terdiri dari 7 (tujuh) jenis kayu yaitu: akasia (*Acacia mangium*), jati (*Tectona grandis*), mahoni (*Swietenia mahagoni*), sengon laut (*Paraserianthes falcataria*), sengon tekik (*Paraserianthes falcataria*), trembesi (*Samanea Saman*) and waru (*Hibiscus tiliaceus*).

Adapun peralatan yang diperlukan untuk mengukur kekuatan kayu berdasarkan berat jenisnya antara lain: alat tulis menulis, gergaji, timbangan digital dengan akurasi 0,1 gram, gelas ukur volume dengan skala 10 ml, serta alat pengukur kadar air kayu. Potongan kayu uji dan alat yang digunakan bisa dilihat pada Gambar 3.2.



Gambar 3.2 Alat dan Kayu Uji

Parameter yang digunakan untuk pengukuran kelas kuat kayu adalah berat jenis pada kondisi kering udara sesuai dengan SNI 03-6847-2002. Langkah untuk menentukan berat jenis kayu dijabarkan sebagai berikut:

1. Haluskan permukaan kayu agar mudah dalam proses pengukuran;
2. Siapkan tiga sampel potongan untuk setiap jenis kayu dengan ukuran (50x50x50) mm;
3. Ukur kadar air kayu dan pastikan kayu berada pada kondisi kering udara (kadar air < 20%);
4. Timbang massa kayu (m) menggunakan timbangan digital (gram);
5. Ukur volume kayu (V) dengan menggunakan gelas ukur berisi air tawar (ml), dengan menghitung selisih volume sebelum dan sesudah kayu dimasukkan ke dalam air;
6. Berat jenis kayu dihitung menggunakan Persamaan 2.1;
7. Ulangi perhitungan berat jenis untuk semua sampel dan hitung rata-ratanya dari setiap jenis kayu;
8. Dari rata-rata berat jenis kayu dapat ditentukan kelas kuatnya berdasarkan Tabel 3.1.


Tabel 3.1 Kelas Kuat Kayu Berdasarkan Berat Jenis

No	Rata-Rata Berat Jenis	Kelas Kuat	Keterangan
1	> 0,90	I	Sangat Kuat
2	0,60- 0,90	II	Kuat
3	0,40 - 0,60	III	Sedang
4	0,30 - 0,40	IV	Lemah
5	< 0,30	V	Sangat lemah

Hasil dari pengukuran kelas kuat kayu berdasarkan berat jenis akan menjadi dasar pelabelan data pada tahap klasifikasi. Dari tujuh jenis kayu yang dijadikan objek penelitian, besar kemungkinan tidak akan mewakili setiap kelas kuat yang ada. Karena sesuai dengan batasan masalah penelitian, untuk kayu yang digunakan sebagai bahan baku pembuatan rumah dan mebel didominasi oleh kayu dengan rentang kelas kuat II-IV. Kayu dengan Kelas Kuat I umumnya sangat keras dan sulit untuk diolah sebagai bahan baku mebel. Sedangkan kayu dengan Kelas Kuat V umumnya sangat rapuh dan tidak tahan lama sehingga dihindari sebagai bahan baku pembuatan rumah dan mebel.

3.2 Pengambilan Gambar


Alat yang dibutuhkan dalam pengambilan gambar adalah: kamera DSLR, *tripod* dan *background* berwarna hitam. Untuk proses pengambilan gambar menggunakan balok kayu dengan ukuran (50x50x100) mm. Pengambilan gambar dilakukan menggunakan kamera DSLR Canon EOS 600D terhadap permukaan balok kayu dengan posisi berdiri sehingga ukuran kayu yang didapatkan adalah (50x100) mm.



Gambar 3.3 Ilustrasi Pengambilan Gambar

Kamera diatur dalam mode manual dengan pengaturan ISO 200, kecepatan *shutter* 1/60, dan *aperture* F10. Kamera diposisikan sejajar dengan balok kayu dengan jarak 30 cm seperti diilustrasikan pada Gambar 3.3. Untuk sudut pengambilan gambar menggunakan *eye level* yaitu sejajar lurus dengan objek. Sedangkan untuk ukuran gambar menggunakan *full shot* dengan posisi *portrait* sesuai ukuran balok kayu. Rasio yang digunakan berukuran 9:16 dengan kualitas medium sehingga didapatkan *file* mentah berukuran (1.944 x 3.456) piksel.

Sebelum memotret pastikan permukaan kayu bebas dari cacat dan dihaluskan terlebih dahulu agar teksturnya terlihat dengan jelas. Pengambilan citra dilakukan pada ruangan minim cahaya, dengan *background hitam* dan hanya memanfaatkan pencahayaan dari lampu flash kamera. Sehingga intensitas cahaya yang diterima oleh masing-masing kayu bisa setara. Masing-masing kayu diambil citranya sebanyak 25-35 gambar. Langkah pengambilan gambar bisa dilihat pada Gambar 3.4.




Gambar 3.4 Langkah Pengambilan Gambar

3.3 Pre-Processing

Inti dari tahap *pre-processing* dalam pengolahan citra adalah agar gambar bisa mudah diolah dan meningkatkan kemungkinan dalam keberhasilan pada tahap pengolahan citra digital berikutnya. Proses pertama yang harus dilakukan adalah penyesuaian ukuran gambar (*crop*) dari ukuran asli sebesar (1.944 x 3.456) piksel. Ukuran gambar setelah *cropping* adalah (700 x 1.400) piksel dengan menghilangkan *background* hitam. Pemilihan ukuran ini dengan pertimbangan agar tidak terlalu berat dalam proses ekstraksi fitur, namun juga tidak mengorbankan detail dari gambar. Dengan ukuran gambar (700 x 1.400) piksel detail dari tekstur kayu masih bisa terlihat dengan jelas.

Selanjutnya citra yang didapatkan dari proses pengambilan gambar dikonversi menjadi dua jenis, yaitu citra RGB (Gambar 3.5a) dan citra *Grayscale* seperti pada gambar 3.5b. Proses konversi gambar menggunakan *tool library cv2*.


Citra RGB digunakan untuk ekstraksi fitur dari parameter warna, sedangkan *grayscale* digunakan untuk ekstraksi fitur dari parameter tekstur menggunakan metode GLCM.




Gambar 3.5 Citra RGB (a), Citra *Grayscale* (b)

3.4 Ekstraksi dan Seleksi Fitur

Untuk proses ekstraksi dan seleksi fitur, *tool* yang digunakan yaitu bahasa pemrograman python dengan bantuan *library* cv2 dan mahotas yang memang dikhususkan untuk mempermudah pengolahan citra. Untuk ekstraksi fitur dari parameter warna, penelitian ini mengadopsi metode pembuatan histogram kanal RGB. Kemudian dari histogram tersebut akan menghasilkan ekstraksi fitur berupa nilai rata-rata/*average* masing-masing kanal seperti pada Gambar 3.6. Sehingga dari proses ini didapatkan tiga (3) fitur, yaitu rata-rata nilai kanal *Red*, *Green* dan *Blue*. Gambar 3.6a menunjukkan ekstraksi fitur pada salah satu sampel kayu akasia yang menghasilkan nilai rata-rata untuk kanal *Red* sebesar 191, kanal *Green* sebesar 125 dan Kanal *Blue* sebesar 87. Sedangkan Gambar 3.6b merupakan ekstraksi fitur pada salah satu sampel kayu Sengon Tekek yang menghasilkan nilai 176 untuk kanal *Red*, 153 untuk kanal *Green* dan 130 untuk kanal *Blue*.



(a)




(b)

Gambar 3.6 Histogram Citra Kayu Akasia (a) dan Sengon Tekek (b)

Sedangkan untuk GLCM, proses ekstraksi fitur akan menggunakan beberapa percobaan data untuk dibandingkan hasilnya. Data yang digunakan merupakan output dari sudut 0° , 45° , 90° , 135° serta nilai rata-rata dari keempat sudut tersebut, semuanya menggunakan jarak (*distance*) 1 piksel. Dengan menggunakan *library mahotas* (Coelho, 2013), didapatkan 13 fitur yang meliputi: *Angular Second Moment*, *Contrast*, *Correlation*, *Variance*, *Inverse Difference Moment*, *Sum Average*, *Sum Variance*, *Sum Entropy*, *Entropy*, *Difference Variance*, *Difference Entropy*, *Information Measure of Correlation 1*, dan *Information Measure of Correlation 2*. Sehingga didapatkan lima dataset dengan

masing-masing dataset berisikan 13 fitur. Kemudian dipilih satu dataset dari proses GLCM yang mempunyai akurasi paling baik.

Selanjutnya semua fitur yang didapatkan dari kanal RGB dan GLCM akan digabung dan diseleksi jumlah optimalnya menggunakan metode *Recursive Feature Elimination Cross Validation* (RFECV). Seleksi fitur dibutuhkan karena jumlah fitur yang masih terlalu besar, yaitu 16 fitur. Dengan adanya proses seleksi fitur diharapkan bisa mereduksi jumlah fitur sekaligus meningkatkan performa klasifikasi. Karena termasuk dalam *wrapper selector*, RFECV akan menggunakan beberapa algoritma sebagai estimator, yaitu: *Linear Discriminant Analysis* (LDA), *Logistic Regression* (LR), *Random Forest* (RF) dan *Decision Tree* (CART). Secara umum, alur seleksi fitur tersaji pada Gambar 3.7.



Gambar 3.7 Alur Seleksi Fitur


Metode RFECV mampu memberikan bobot ke fitur melalui atribut *coefficients* dan *feature_importance*. Kemudian, fitur yang paling rendah bobotnya dipangkas dari dataset. Prosedur itu secara berulang diulang hingga dataset terkecil sehingga dapat diketahui jumlah fitur yang optimal. Kemudian dengan menggunakan metode RFE akan dihilangkan fitur yang berbobot rendah. Algoritma ini menghasilkan fitur yang memiliki bobot paling tinggi sejumlah fitur

optimal dari algoritma RFECV. Selain itu, RFE juga bisa digunakan untuk meranking bobot/score tiap fitur berdasarkan hubungannya dengan variabel output.

Sebelum diklasifikasikan, nilai fitur harus *scaling* terlebih dahulu. Metode ini merupakan salah satu metode *pre-processing* data dalam *machine learning* agar data yang digunakan siap digunakan dalam proses selanjutnya. Hal ini disebabkan karena beberapa variabel biasanya memiliki nilai yang sangat bervariasi dan random, ada yang sangat besar dan sangat kecil. Dengan proses *feature scale* diharapkan hasil proses klasifikasi tidak condong hanya ke fitur-fitur yang bernilai besar. Metode yang digunakan dalam proses *feature scale* adalah algoritma *MinMaxScaler* dengan rentang nilai 0-1.

3.5 Klasifikasi dan Evaluasi Model

Sebelum proses klasifikasi, dataset harus sudah dilabeli terlebih dahulu. Pelabelan dataset merupakan proses dimana penggabungan dan rekapitulasi hasil dari ekstraksi fitur dalam sebuah table matriks, dimana kolom tabel terdiri dari fitur atau atribut yang digunakan dan label kelas, sedangkan baris tabel sebagai *instance* dari dataset. Pada penelitian ini, label merupakan kelas kuat kayu yang merupakan hasil pengukuran kekuatan kayu berdasarkan berat jenis. Sedangkan nilai fitur diambil dari hasil proses seleksi fitur sebelumnya. Alur dari proses klasifikasi dan evaluasi model tersaji pada Gambar 3.8.



Gambar 3.8 Alur Klasifikasi dan Evaluasi Model

Setelah dilakukan proses pelabelan, lima metode klasifikasi akan digunakan untuk menguji performa dari fitur yang dipilih. Berikut 5 (lima) algoritma klasifikasi yang digunakan dalam penelitian ini:

1. K-Nearest Neighbor (KNN)
2. Linear Discriminant Analysis (LDA)
3. Decision Tree (CART)
4. Random Forest (RF)
5. Support Vector Machines (SVM)

Khusus untuk algoritma KNN dan *Random Forest* akan dilakukan *tuning* terlebih dahulu untuk menentukan parameter *n_neighbors* dan *n_estimators*. Parameter *n_neighbors* merupakan jumlah tetangga yang akan digunakan sebagai pengukuran jarak terdekat pada metode KNN. Sedangkan *n_estimators* adalah jumlah pohon keputusan yang akan digunakan untuk penghitungan *majority-vote* pada metode *Random Forest*

Untuk proses klasifikasi dibagi menjadi dua tahap yaitu klasifikasi data *training* dan data *testing*. Perbandingan antara jumlah data *training* dan *testing* sebanyak 80:20. Untuk menguji kelima algoritma yang telah ditentukan, penelitian ini menggunakan metode *K-Fold Cross Validation*, dengan nilai $K = 10$. Tujuan utama menggunakan metode ini adalah untuk mengurangi resiko adanya *overfitting* maupun *underfitting* karena semua data akan digunakan secara bergantian sebagai data *training* dan *testing*. Selain itu, metode ini juga bisa mengurangi waktu komputasi dengan tetap mempertahankan keakuratan hasil klasifikasi.

Dari proses klasifikasi data *training* akan ditemukan model terbaik di antara lima algoritma klasifikasi. Ada enam pengukuran (*model evaluation*) yang dijadikan tolak ukur dalam menentukan performa algoritma klasifikasi terbaik, yaitu: *accuracy*, *precision*, *recall*, *f1-score*, AUC dan waktu kecepatan pengujian. Untuk mempermudah dalam evaluasi model, hasil klasifikasi akan dibentuk dalam format *confusion matrix*.

Selanjutnya model terbaik akan diuji dengan data *testing* untuk mengukur sejauh mana *classifier* berhasil melakukan klasifikasi dengan benar. Dalam penelitian ini juga akan dilakukan pengujian sejauh mana perbedaan performa jika

menggunakan hanya satu parameter warna atau tekstur, dan menggabungkan antara keduanya serta menguji sejauh mana perbedaan klasifikasi sebelum dan setelah seleksi fitur.

Halaman ini sengaja dikosongkan

BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini akan dijelaskan secara detail mengenai hasil penelitian dan analisa mengenai klasifikasi kekuatan kayu berdasarkan parameter warna dan tekstur citra.

4.1 Uji Kekuatan Kayu dan Pelabelan

Untuk memvalidasi kelas kuat kayu, akan dilakukan Uji Berat Jenis yang digunakan sebagai dasar penentuan Kelas Kuat Kayu. Pengujian ini menggunakan tiga sampel untuk setiap jenis kayu dengan ukuran $\pm(50 \times 50 \times 50)$ mm. Karena penelitian ini menggunakan tujuh jenis kayu maka total balok kayu yang diperlukan untuk pengukuran berat jenis ini adalah sebanyak 21 buah. Langkah pertama dalam menentukan kelas kuat kayu adalah mengukur kadar air dengan menggunakan *wood moisture meter* seperti pada Gambar 4.1.



Gambar 4.1 Pengukuran Kadar Air Kayu pada Sengon Laut

Nilai pengukuran kadar air kayu harus $< 20\%$ yang menandakan bahwa kayu dalam kondisi kering udara. Untuk Kayu Akasia, pengukuran kadar air menunjukkan nilai 13-14%. Kadar air Kayu Jati antara 13-15%. Nilai kadar air Kayu Mahoni sebesar 14-16%. Kadar air Kayu Sengon Laut dan Sengon Tekek masing-masing adalah 13-15% dan 12-14%. Sedangkan Kayu Trembesi mempunyai kadar kayu 16-20%. Dan terakhir Kayu Waru memiliki kadar air 12-14%. Berdasarkan pengukuran kadar air, semua balok kayu yang telah disiapkan memenuhi syarat untuk dijadikan obyek penelitian karena dalam kondisi kering udara.



Gambar 4.2 Menimbang Balok Kayu Mahoni

Langkah selanjutnya adalah menimbang balok untuk diketahui *massa*-nya. Dalam penelitian ini digunakan timbangan digital dengan akurasi 0,1 gram seperti pada Gambar 4.2. Massa kayu hasil pengukuran secara lengkap tersaji dalam Tabel 4.1.

Tabel 4.1 Pengukuran Massa Kayu

No	Jenis Kayu	Massa (gram)		
		Kayu 1	Kayu 2	Kayu 3
1	Akasia	95,3	102,4	113,3
2	Jati	87,7	89,4	85,7
3	Mahoni	78,7	82,5	79,0
4	Sengon Laut	49,6	43,3	38,3
5	Sengon Tekek	48,8	46,5	50,4
6	Trembesi	69,0	60,9	61
7	Waru	77	73,6	73,7

Langkah selanjutnya adalah mengukur volume kayu. Penelitian ini menggunakan metode celup air menggunakan gelas ukur dengan volume maksimal 1000 ml dan skala 10 ml. Metode ini sesuai dengan Standar Nasional Indonesia (SNI) Nomor 03-6847-2002. Dalam metode ini yang perlu diperhatikan adalah balok kayu harus dipastikan tercelup semua di dalam air seperti pada Gambar 4.3.



Gambar 4.3 Pengukuran Volume Kayu

Volume kayu adalah selisih antara volume air awal dengan volume air sesudah dicelupkan kayu ke dalamnya. Hasil pengukuran volume kayu ditampilkan dalam Tabel 4.2.

Tabel 4.2 Hasil Pengukuran Volume Kayu

No	Jenis Kayu	Volume (ml)		
		Kayu 1	Kayu 2	Kayu 3
1	Akasia	130	140	150
2	Jati	130	130	130
3	Mahoni	125	125	125
4	Sengon Laut	120	120	120
5	Sengon Tekek	120	120	125
6	Trembesi	135	135	130
7	Waru	140	140	135

Dari hasil pengukuran massa dan volume di atas, bisa dihitung berat jenis dengan menggunakan Persamaan 2.1 dan Persamaan 2.2. Rata-rata nilai berat jenis dari ketiga sampel bisa diklasifikasikan kelas kuatnya berdasarkan Tabel 3.1. Hasil perhitungan berat jenis dan kelas kuat kayu ditampilkan secara detail pada Tabel 4.3.

Tabel 4.3 Hasil Pengukuran Kelas Kuat Kayu

No	Nama Kayu	Berat Jenis			μ BJ	Kelas Kuat
		Kayu 1	Kayu 2	Kayu 3		
1	Akasia	0,73	0,73	0,75	0,74	II
2	Jati	0,68	0,69	0,66	0,67	II
3	Mahoni	0,63	0,66	0,63	0,64	II
4	Sengon laut	0,41	0,36	0,32	0,36	IV
5	Sengon tekek	0,41	0,39	0,40	0,40	IV
6	Trembesi	0,51	0,45	0,47	0,48	III
7	Waru	0,55	0,53	0,55	0,54	III

Dari pengukuran kelas kuat terhadap 7 (tujuh) jenis kayu, didapatkan bahwa akasia, jati dan mahoni masuk kelas kuat II. Kayu waru dan trembesi termasuk kelas kuat III, sedangkan sengon laut dan sengon tekek termasuk kelas Kuat IV. Tidak ada kayu yang masuk kelas kuat I dan kelas kuat V, dikarenakan untuk bahan baku rumah dan mebel, kelas kuat I sulit diolah karena terlalu keras sedangkan kelas kuat V terlalu rapuh sehingga tidak tahan lama.

Berdasarkan buku induk dan riset di bidang kehutanan diketahui bahwa rata-rata berat jenis Kayu Akasia adalah 0,63 (Purwanto, 2012), Kayu Jati 0,67 (Martawijaya et al., 2005), Kayu Mahoni 0,62 (Martawijaya et al., 2005), Kayu Sengon Laut dan Sengon Tekek 0,33 (Martawijaya et al., 1989), Kayu Trembesi 0,44 (Hidayati and Siagian, 2012) dan Kayu Waru 0,54 (Suprpti, Djarwanto and Hudiansyah, 2004). Perbandingan kelas kuat serta label klasifikasi antara hasil pengukuran dan validasi dari penelitian sebelumnya di jabarkan dalam Tabel 4.4 di bawah ini.

Tabel 4.4 Validasi Kelas Kuat Kayu dan Pelabelan


No	Nama Kayu	Pengukuran		Validasi		Label
		μ BJ	Kelas Kuat	μ BJ	Kelas Kuat	
1	Akasia	0,74	II	0,63	II-III	2
2	Jati	0,67	II	0,67	II	2
3	Mahoni	0,64	II	0,64	II-III	2
4	Sengon Laut	0,36	IV	0,33	IV-V	4
5	Sengon Tekek	0,40	IV	0,33	IV-V	4
6	Trembesi	0,48	III	0,44	III	3
7	Waru	0,54	III	0,54	III	3

Walaupun terdapat perbedaan rata-rata berat jenis antara hasil pengukuran dengan validasi dari referensi kehutanan pada Tabel 4.4, namun kelas

kuat kayu masih dalam rentang kelas yang sama. Sehingga label data untuk Kayu Akasia, Jati dan Mahoni adalah Kelas 2. Label untuk Kayu Trembesi dan Waru adalah Kelas 3. Sedangkan label untuk Kayu Sengon Laut dan Sengon Tekek adalah Kelas 4.

4.2 Pengambilan Gambar dan *Pre-Processing*

Proses pengambilan gambar merupakan langkah paling krusial dalam penelitian ini. Hasil akhir dari penelitian sangat ditentukan dari sebgus apa citra yang didapatkan. Agar intensitas cahaya yang diterima setara, ketujuh jenis kayu dipotret pada kondisi minim cahaya dengan menggunakan *background* hitam dan hanya menggunakan cahaya dari lampu *flash* bawaan kamera. Sampel hasil potret citra kayu dapat dilihat pada Gambar 4.4. Ukuran resolusi yang didapatkan dari hasil foto sebesar (1.944 x 3.456) piksel.



Gambar 4.4 Sampel Gambar Mentah Hasil Foto

Total citra yang diambil dari 7 (tujuh) jenis kayu berjumlah 221 gambar, dengan rincian Kayu Akasia sebanyak 25 citra, Kayu Jati sebanyak 35 citra, Kayu Mahoni sebanyak 35 citra, Kayu Trembesi sebanyak 34 citra, Kayu Waru sebanyak 32 citra, Kayu Sengon Laut dan Sengon Tekek masing-masing sebanyak 30 citra. Dari citra tersebut akan dibagi 80% atau 178 citra sebagai data *training* dan 20% atau 43 citra sebagai data *testing*. Bila dikelompokkan berdasarkan kelasnya, untuk Kelas II didapatkan sebanyak 95 citra, Kelas III sebanyak 66 citra dan Kelas IV sebanyak 60 citra. Rincian jumlah pengambilan citra tersaji dalam Tabel 4.5.

Tabel 4.5 Rincian Pengambilan Data Citra

No	Nama kayu	Jumlah Data Citra			Label	Jumlah @ kelas
		Train	Test	Total		
1	Akasia	20	5	25	2	95
2	Jati	28	7	35		
3	Mahoni	28	7	35		
4	Trembesi	28	6	34	3	66
5	Waru	26	6	32		
6	Sengon Laut	24	6	30	4	60
7	Sengon Tekek	24	6	30		
	Total	178	43	221		

Dengan resolusi sebesar (1.944 x 3.456) piksel, tekstur pada gambar terlihat dengan jelas namun kekurangannya membutuhkan memori terlalu besar dan waktu pemrosesan yang terlalu lama baik untuk ekstraksi fitur maupun proses klasifikasi data. Sehingga dalam proses *pre-processing* perlu dilakukan pengecilan resolusi citra sekaligus menghilangkan *background* berwarna hitam. Ukuran citra setelah diresize menjadi (700 x 1.400) piksel sedangkan untuk

background hitam dihilangkan secara manual. Pemilihan ukuran ini dengan pertimbangan agar tidak terlalu berat dalam proses ekstraksi fitur dan proses-proses pengolahan citra selanjutnya, namun juga tidak mengorbankan detail tekstur dari gambar. Hasil sampel citra setelah melalui tahapan *pre-processing* tersaji dalam Gambar 4.5.



Gambar 4.5 Citra setelah *Pre-processing*

4.3 Ekstraksi dan Seleksi Fitur

Sesuai dengan metode yang telah dipaparkan sebelumnya, ekstraksi fitur menggunakan parameter warna dan tekstur. Untuk proses ekstraksi dan seleksi fitur, *tool* yang digunakan yaitu bahasa pemrograman python dengan bantuan *library* cv2 dan mahotas yang memang dikhususkan untuk mempermudah pengolahan citra. Untuk ekstraksi fitur dari parameter warna, penelitian ini mengadopsi metode pembuatan histogram kanal RGB. Kemudian dari histogram tersebut akan menghasilkan ekstraksi fitur berupa nilai rata-rata/*average* masing-masing kanal. Sedangkan untuk ekstraksi parameter tekstur menggunakan metode GLCM (*Gray Level Co-Occurrence Matrix*) yang nilainya diambil dari citra *grayscale*. Untuk GLCM, proses ekstraksi fitur akan menggunakan beberapa

percobaan data untuk dibandingkan hasilnya. Data yang digunakan merupakan output dari sudut 0° , 45° , 90° , 135° serta nilai rata-rata dari keempat sudut tersebut, semuanya menggunakan jarak (*distance*) 1 piksel.

Gambar yang digunakan untuk proses ekstraksi fitur berformat JPG/JPEG dengan kualitas 24-bit untuk yang warna RGB dan 8-bit untuk yang *grayscale*. Perbandingan antara citra RGB dan citra *grayscale* dapat dilihat pada Gambar 4.6.



Gambar 4.6 Perbandingan Citra RGB dan *Grayscale*

Ekstraksi fitur dari parameter warna menghasilkan tiga fitur yaitu: nilai rata-rata kanal R (*Red*), kanal G (*Green*), kanal B (*Blue*). Tabel 4.6 menampilkan nilai hasil ekstraksi fitur warna dari 178 citra kayu *training*.

Tabel 4.6 Nilai Ekstraksi Fitur Warna RGB

Kelas Kuat	Kayu No.	Blue	Green	Red
II	1	125,705	129,131	139,434
	2	104,427	122,178	145,254
	3	89,774	103,091	126,255
	4	99,586	117,632	145,864
				
	76	109,345	117,803	133,240
III	77	142,022	150,234	163,656
	78	142,467	146,634	156,863
	79	126,663	140,289	167,917
	80	146,763	148,737	156,797
				
	130	151,408	153,983	163,437
IV	131	107,710	109,622	121,832
	132	117,620	109,974	113,310
	133	111,739	105,148	109,314
	134	127,074	142,948	173,841
				
	178	109,811	109,469	118,650

Sedangkan paramater tekstur dengan algoritma GLCM menghasilkan 13 fitur yaitu: *Angular Second Moment, Contrast, Correlation, Variance, Inverse Different Moment, Entropy, Sum Average, Sum Variance, Sum Entropy, Difference Variance, Difference Entropy, Measure of Correlation I, dan Measure of Correlation II*. Hasil dari ekstraksi fitur GLCM sebanyak lima dataset, yaitu menggunakan sudut 0° , 45° , 90° , 135° dan rata-rata dari semua sudut tersebut. Kelima dataset tersebut menggunakan jarak (*distance*) sebesar 1 (satu) piksel. Beberapa sampel dari hasil ekstraksi fitur menggunakan metode GLCM ditampilkan dalam Tabel 4.7.

Tabel 4.7 Sampel Ekstraksi Fitur GLCM

	0°		45°		90°		135°		Mean	
ASM	0,0020	0,0010	0,0017	0,0010	0,0031	0,0019	0,0019	0,0009	0,0022	0,0012
Cont.	11,816	30,304	16,298	31,942	4,5094	7,5043	12,884	37,624	11,377	26,844
Corr.	0,9660	0,9524	0,9531	0,9498	0,9870	0,9882	0,9629	0,9409	0,9673	0,9578
Var.	173,81	318,30	173,74	318,18	174,02	318,68	173,75	318,19	173,83	318,34
IDM	0,3522	0,2515	0,3071	0,2359	0,4672	0,3917	0,3265	0,2246	0,3633	0,2759
$\sum$ Avg	263,65	254,10	263,65	254,10	263,65	254,11	263,65	254,10	263,65	254,10
$\sum$ Var.	683,44	1242,9	678,70	1240,8	691,58	1267,2	682,11	1235,1	683,96	1246,5
$\sum$ Entr.	6,7330	7,1620	6,7281	7,1605	6,7419	7,1748	6,7309	7,1573	6,7335	7,1636
Entr.	9,4721	10,554	9,7083	10,605	8,8124	9,6045	9,5476	10,718	9,3851	10,370
Δ Var.	0,0009	0,0006	0,0008	0,0006	0,0013	0,0011	0,0008	0,0005	0,0010	0,0007
Δ Entr.	2,9144	3,5405	3,1227	3,5838	2,3045	2,6367	2,9792	3,6923	2,8302	3,3633
MoC I	-0,3517	-0,2917	-0,3105	-0,2836	-0,4667	-0,4457	-0,3385	-0,2652	-0,3668	-0,3216
MoC II	0,9912	0,9863	0,9858	0,9849	0,9977	0,9980	0,9897	0,9810	0,9911	0,9875

Ket.:

ASM : Angular Second Moment

Cont. : Contrast

Corr. : Correlation

Var. : Variance

IDM : Inverse Different Moment

$\sum$ Avg : Sum Average

$\sum$ Var. : Sum Variance

$\sum$ Entr. : Sum Entropy

Entr. : Entropy

Δ Var. : Difference Variance


Δ Entr. : Difference Entropy

MoC I : Measure of Correlation I

MoC II : Measure of Correlation II

Selanjutnya dari lima (5) dataset hasil ekstraksi fitur GLCM akan dipilih satu dataset terbaik menggunakan metode *Recursive Feature Elimination Cross*

Validation (RFECV). Metode ini memungkinkan menghitung rata-rata akurasi pada setiap jumlah fitur dengan menggunakan beberapa estimator klasifikasi tertentu.




Gambar 4.7 Seleksi Fitur GLCM dengan Estimator LDA

Dengan menggunakan dua estimator yaitu *Linear Discriminant Analysis* (LDA) dan *Logistic Regression* (LR), dataset dengan akurasi terbaik didapatkan ketika menggunakan fitur dari sudut 0° . Untuk estimator LDA, nilai akurasi tertinggi didapatkan sebesar 86,5% dengan menggunakan sudut 0° dan fitur sebanyak 10 buah. Hasil rata-rata akurasi tertinggi untuk LDA juga diperoleh menggunakan sudut 0° dengan nilai 74,3%. Menyusul di bawahnya secara berurutan sudut 45° dengan 71,7%, sudut 135° dengan 71,6%, mean dengan 70,1% dan yang paling terakhir sudut 90° dengan nilai 59,9%. Hasil selengkapnya bisa dilihat pada Gambar 4.7.

Sedangkan untuk estimator LR, akurasi terbaik didapatkan ketika menggunakan sudut 0° . Hal ini terlihat dari Gambar 4.8 dimana sudut 0° mengungguli sudut yang lain di hampir di semua titik, akurasi tertinggi didapatkan sebesar 89,9% dengan jumlah fitur sebanyak 10 buah. Untuk rata-rata

akurasi tertinggi juga didapatkan ketika menggunakan sudut 0° dengan nilai sebesar 80,5%. Menyusul di bawahnya secara berurutan sudut 135° dengan 77,2%, sudut 45° dengan 74,5%, mean dengan 72% dan yang paling terakhir sudut 90° dengan nilai 59,8%.



Gambar 4.8 Seleksi Fitur GLCM dengan Estimator LR

Berdasarkan hasil seleksi di atas, ekstraksi fitur GLCM terbaik menggunakan sudut 0° dan jarak (*distance*) 1 piksel. Selanjutnya fitur warna dan tekstur digabungkan kemudian diseleksi untuk menentukan fitur mana yang dibuang atau digunakan melalui proses perangkingan. Untuk proses ini, ada dua tahap yang perlu dilakukan:

1. Menentukan jumlah fitur optimal

Untuk tahap ini menggunakan metode *Recursive Feature Elimination Cross Validation* (RFECV) dengan bantuan empat algoritma estimator yaitu *Linear Discriminant Analysis* (LDA), *Logistic Regression* (LR), *Random Forest* (RF) dan *Classification and Regression Tree* (CART) didapatkan rata-rata akurasi seperti pada Tabel 4.8.

Tabel 4.8 Akurasi Per Jumlah Fitur Menggunakan RFE

Jumlah Fitur	Estimator				Rata-Rata
	LDA	LR	RF	CART	
1	0,680	0,517	0,713	0,742	0,663
2	0,669	0,697	0,837	0,831	0,758
3	0,798	0,770	0,843	0,820	0,808
4	0,787	0,815	0,888	0,854	0,826
5	0,815	0,843	0,916	0,826	0,850
6	0,826	0,865	0,888	0,854	0,858
7	0,843	0,904	0,876	0,871	0,874
8	0,831	0,916	0,899	0,843	0,872
9	0,865	0,904	0,893	0,865	0,882
10	0,888	0,899	0,888	0,848	0,881
11	0,899	0,893	0,882	0,860	0,883
12	0,888	0,899	0,876	0,871	0,883
13	0,893	0,899	0,888	0,837	0,879
14	0,893	0,882	0,865	0,854	0,874
15	0,893	0,888	0,871	0,815	0,867
16	0,893	0,882	0,882	0,831	0,872

Dari Tabel 4.8 di atas terlihat bahwa setiap algoritma menghasilkan jumlah fitur optimal yang berbeda berdasarkan tingkat akurasi. Untuk *Linear Discriminant Analysis* (LDA) jumlah fitur optimalnya 11 fitur dengan nilai akurasi 89,9%, *Logistic Regression* (LR) fitur optimalnya adalah 8 fitur dengan akurasi 91,6%, *Random Forest* (RF) dan *Classification and Regression Tree* (CART) masing-masing fitur optimalnya adalah 5 fitur dengan akurasi 91,6% dan 7 fitur dengan akurasi 87,1%. Jumlah fitur optimal yang akan digunakan untuk proses selajutnya adalah rata-rata terbaik yaitu menggunakan 11 fitur dengan akurasi 88,3%.

2. Membuat fitur dengan bobot rendah

Dengan menggunakan RFE didapatkan 11 fitur yang mempunyai hubungan kuat dengan variabel output sekaligus membuang lima fitur yang kurang berpengaruh. Lima fitur yang dihapus sekaligus yang berbobot paling rendah adalah *Difference Variance*, *Angular Second Moment*, *Sum Variance*, *Sum Average* dan *Sum Entropy*. Dengan metode ini pula bisa diketahui rangking tiap-tiap fitur terhadap variabel output, berikut secara berurutan dari yang terbesar dalam Tabel 4.9.

Tabel 4.9 Rangking Fitur Berurutan dari yang Terbesar

No	Feature	No	Feature
1	Measure of Correlation II	9	Contrast
2	Correlation	10	Variance
3	Blue	11	Entropy
4	Green	12	Sum Entropy
5	Red	13	Sum Average
6	Measure of Correlation I	14	Sum Variance
7	Inverse Different Moment	15	Angular Second Moment
8	Difference Entropy	16	Difference Variance

Dari Tabel 4.9 terlihat bahwa semua fitur yang diambil dari parameter warna mendominasi rangking tertinggi. Hal ini menunjukkan bahwa unsur warna memiliki pengaruh yang besar dalam proses klasifikasi. Untuk GLCM, rangking tinggi dipengaruhi oleh fitur *correlation* dan turunannya. Sedangkan fitur yang mempunyai bobot rendah dari GLCM didominasi oleh fitur turunan. Hal ini terlihat dari empat fitur turunan yang menempati rangking terendah yaitu *Difference Variance*, *Sum Variance*, *Sum Average* dan *Sum Entropy*. Dari Tabel 4.9 juga terlihat bahwa fitur *Variance* dan *Entropy* beserta turunannya memiliki bobot yang cenderung rendah.

Langkah terakhir sebelum dilakukan klasifikasi adalah dengan melakukan normalisasi data berupa *feature scale*. Dengan proses *feature scale* diharapkan hasil proses klasifikasi tidak condong hanya ke fitur-fitur yang bernilai besar. Metode yang digunakan dalam proses *feature scale* adalah algoritma *MinMaxScaler* dengan rentang nilai 0-1. Transformasi data sebelum dan setelah menggunakan *MinMaxScaler* dapat dilihat pada Tabel 4.10.

Tabel 4.10 Transformasi Data Menggunakan *MinMaxScaler*

Feature	Sebelum <i>Scaling</i>					Setelah <i>Scaling</i>				
Blue	99,70	105,6	112,8	114,9	118,3	0,292	0,362	0,446	0,471	0,512
Green	113,2	119,7	120,9	125,1	132,2	0,370	0,455	0,470	0,525	0,619
Red	131,4	141,2	135,0	138,4	149,0	0,376	0,502	0,422	0,466	0,603
Cont.	21,09	16,66	20,50	18,68	11,71	0,434	0,319	0,419	0,371	0,190
Corr.	0,940	0,990	0,960	0,950	0,960	0,453	0,963	0,618	0,546	0,678
IDM	0,270	0,290	0,280	0,280	0,330	0,229	0,305	0,262	0,266	0,452
Σ Avg	234,2	249,0	248,4	255,9	271,3	0,376	0,474	0,470	0,520	0,623
Σ Entr.	6,740	7,520	6,910	6,780	6,650	0,447	0,847	0,534	0,468	0,399
Entr.	9,920	10,56	10,07	9,890	9,410	0,614	0,810	0,660	0,606	0,459
MoC I	-0,28	-0,39	-0,30	-0,30	-0,34	0,725	0,307	0,606	0,663	0,492
MoC II	0,980	1,000	0,990	0,980	0,990	0,554	0,951	0,459	0,643	0,772

4.4 Klasifikasi Data dan Evaluasi Model


Klasifikasi data terbagi menjadi dua proses, yaitu *training* dan *testing*.

4.4.1 Data Training

Selain dilakukan uji performa algoritma klasifikasi untuk menemukan model terbaik, juga akan dilakukan pengujian sejauh mana pengaruh proses seleksi fitur dan pemilihan parameter terhadap hasil pengujian.


4.4.1.1 Uji Performa Algoritma Klasifikasi

Proses klasifikasi data *training* akan menggunakan lima algoritma klasifikasi yaitu : *K-Nearest Neighbor* (KNN), *Linear Discriminant Analysis* (LDA), *Decision Tree* (CART), *Random Forest* (RF), dan *Support Vector Machines* (SVM). Sebelum melakukan klasifikasi, perlu dilakukan *tuning hyperparameter* terlebih dahulu khusus untuk algoritma KNN dan RF. *Hyperparameter* merupakan parameter yang harus ditentukan sebelum melakukan proses *machine learning*, dimana pengaturan parameter ini lebih mengandalkan hasil eksperimen daripada teori. Untuk KNN parameter yang perlu *dituning* adalah jumlah *k_neighbors* atau tetangga terdekatnya. Jumlah *k_neighbors* *dituning* mulai 1 sampai 15. Nilai akurasi terbaik yaitu 93,6% didapatkan saat parameter *k_neighbors* bernilai 1, seperti pada Gambar 4.9.



Gambar 4.9 *Tuning* Parameter *k_neighbors* KNN

Sedangkan parameter pada RF yang *dituning* adalah *n_estimator*, yaitu jumlah pohon klasifikasi. Jumlah *n_estimator* *dituning* dengan nilai antara 1-200. Nilai akurasi terbaik yaitu 91% didapatkan saat parameter *n_estimator* bernilai 50, seperti pada Gambar 4.10




Gambar 4.10 Tuning parameter $n_estimator$ pada RF

Untuk menguji kelima algoritma yang telah ditentukan, penelitian ini menggunakan metode *K-Fold Cross Validation*, dengan nilai $K = 10$. Tujuan utama menggunakan metode ini adalah untuk mengurangi resiko adanya *overfitting* maupun *underfitting* karena semua data akan digunakan baik untuk data *training* maupun untuk data *testing*. Hasil akurasi klasifikasi data *training* dengan menggunakan 11 fitur dan lima algoritma dapat dilihat pada Tabel 4.11.

Tabel 4.11 Hasil Klasifikasi Data *Training* Menggunakan 10-Fold CV

	Jumlah K										μ	Med
	1	2	3	4	5	6	7	8	9	10		
KNN	1,00	1,00	1,00	1,00	0,94	0,83	0,89	0,94	0,94	0,94	0,95	0,94
LDA	1,00	1,00	0,89	0,89	0,89	0,83	0,78	0,89	0,88	1,00	0,90	0,89
CART	0,89	0,89	0,78	0,89	0,94	0,78	0,94	0,94	0,94	0,71	0,87	0,89
RF	0,94	0,89	0,89	1,00	0,94	0,72	0,78	0,89	0,94	0,89	0,89	0,92
SVM	0,94	0,94	0,94	0,83	0,89	0,72	0,78	0,89	0,94	0,94	0,88	0,92


Untuk lebih mudah mengevaluasi, menganalisis dan membandingkan performa akurasi, hasil klasifikasi pada Tabel 4.11 akan diubah ke dalam bentuk *boxplot*. Sehingga terlihat secara jelas rentang hasil akurasi, median, Q1-Q3 sebagaimana pada Gambar 4.11.



Gambar 4.11 *Boxplot* Hasil Klasifikasi Berdasarkan Akurasi

Dari *boxplot* hasil *10-Fold Cross Validation* di atas terlihat bahwa nilai *median* dan *mean* tertinggi didapatkan oleh algoritma KNN sebesar 0,94 dan 0,95, sayangnya ada 1 *outlier* yang sebenarnya nilainya masih cukup tinggi yaitu 0,83. Meskipun demikian, secara keseluruhan akurasi KNN lebih baik dibandingkan algoritma yang lain. Algoritma terbaik kedua adalah LDA karena meskipun nilai rata-rata akurasi hampir sama yaitu 0,90, namun performanya lebih stabil. Hal ini bisa dilihat dari rentang akurasi yang cukup tinggi yaitu antara 0,78-1,00 dan tidak ada nilai *outlier*. Algoritma selanjutnya dengan performa yang cukup baik adalah SVM dan Random Forest. Performa kedua algoritma ini cukup seimbang. Dengan nilai *mean* dan *median* akurasi sekitar 0,9, kedua algoritma ini masih layak untuk digunakan dalam klasifikasi kekuatan kayu. Algoritma terakhir dengan performa terendah adalah CART. Meskipun demikian, algoritma CART juga tidak bisa dikatakan mempunyai performa yang buruk karena nilai rata-rata akurasinya masih cukup tinggi, yaitu 0,87.

Untuk lebih meyakinkan dalam pemilihan algoritma klasifikasi terbaik, juga dilakukan pengukuran nilai *precision*, *recall* dan *f1_score*. Output metode *10-Fold CV* di atas bisa dikonversi menjadi angka dalam bentuk *confusion matrix* sehingga lebih memudahkan dalam perhitungan. Hasil klasifikasi dari lima algoritma di atas dalam bentuk *confusion matrix* tersaji dalam Gambar 4.12.




Gambar 4.12 *Confusion Matrix* Data Training

Precision, *recall* dan *f1_score* dapat dengan mudah dihitung berdasarkan *confusion matrix* di atas. Misalnya: untuk algoritma KNN pada Gambar 4.12a, perhitungan bisa dilakukan sebagai berikut:

$$\begin{aligned}
- \text{ Precision} &= \frac{\text{Prec Kelas 2} + \text{Prec Kelas 3} + \text{Prec Kelas 4}}{n \text{ kelas}} \\
&= \frac{(73/76 + 53/54 + 43/48)}{3} \\
&= 0,95 \\
- \text{ Recall} &= \frac{\text{Rec Kelas 2} + \text{Rec Kelas 3} + \text{Rec Kelas 4}}{n \text{ kelas}} \\
&= \frac{(73/75 + 53/57 + 43/46)}{3} \\
&= 0,94 \\
- \text{ F1 Score} &= 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \\
&= 2 \times \frac{(0,95 \times 0,94)}{(0,95 + 0,94)} \\
&= 0,94
\end{aligned}$$


Dengan mengulangi perhitungan pada seluruh algoritma maka akan didapatkan nilai *precision*, *recall* dan *f1_score* pada Gambar 4.13.



Gambar 4.13 Pengukuran *Precision*, *Recall* dan *F1-score* pada Data Training

Hasilnya KNN masih mengungguli algoritma yang lain pada ketiga metode pengukuran tersebut, disusul oleh LDA, RF, SVM dan terakhir CART. Metode KNN memimpin dengan cukup signifikan seperti yang terlihat pada Gambar 4.13.

Sedangkan untuk nilai AUC-ROC, KNN dan RF mendapatkan nilai terbaik dengan 0,98. Disusul oleh LDA sebesar 0,97, kemudian SVM dengan 0,92 dan terakhir CART dengan nilai AUC sebesar 0,88. Kurva ROC dan nilai AUC dapat dilihat pada Gambar 4.14.



Gambar 4.14 Kurva ROC dan Nilai AUC

Untuk waktu pemrosesan dari kelima algoritma hanya *Random Forest* yang membutuhkan waktu cukup lama yaitu 2 detik/2000 ms. Hal ini wajar, karena *Random Forest* menggabungkan banyak pohon keputusan sehingga membutuhkan waktu yang lebih lama. Sedangkan algoritma yang lain hanya

membutuhkan waktu antara 25-35 ms untuk melakukan klasifikasi data *training*. Detail waktu pemrosesan dapat dilihat pada Tabel 4.12.

Tabel 4.12 Waktu Pemrosesan Tiap Klasifikasi

	KNN	LDA	CART	RF	SVM
Waktu (ms)	34	36	25	2070	28

Dari hasil akurasi, *precision*, *recall*, *f1-score*, AUC dan waktu pemrosesan, metode **KNN** terpilih sebagai algoritma terbaik dalam penelitian ini.


4.4.1.2 Uji Seleksi Fitur

Untuk menguji seberapa besar pengaruh seleksi fitur, klasifikasi data juga akan dilakukan dengan membandingkan penggunaan 16 fitur sebelum diseleksi dan 11 fitur setelah diseleksi. Dengan mengulangi alur proses di atas, klasifikasi dilakukan menggunakan 16 fitur yang belum diseleksi. Hasil klasifikasi dari 16 fitur menggunakan *10-Fold CV* dapat dilihat pada Tabel 4.13.

Tabel 4.13 Hasil Klasifikasi Menggunakan 16 Fitur

	Jumlah K										μ	Med
	1	2	3	4	5	6	7	8	9	10		
KNN	1,00	1,00	1,00	1,00	0,94	0,78	0,83	0,94	0,94	0,94	0,94	0,94
LDA	1,00	1,00	0,89	0,89	0,94	0,83	0,83	0,89	0,88	0,94	0,91	0,89
CART	0,83	0,89	0,83	0,78	0,94	0,78	0,83	0,94	0,94	0,82	0,86	0,83
RF	0,89	0,94	0,89	0,89	0,94	0,67	0,83	0,94	0,94	0,94	0,89	0,89
SVM	0,89	0,94	0,89	0,83	0,83	0,67	0,67	0,89	0,94	0,94	0,85	0,89

Dibandingkan dengan menggunakan 11 fitur, rata-rata akurasi mengalami peningkatan walaupun tidak signifikan. Hal ini menunjukkan bahwa fitur-fitur yang dihapus memang memiliki pengaruh/bobot yang rendah. Baik menggunakan 16 fitur maupun 11 fitur, rata-rata nilai akurasi untuk semua metode di atas 85% seperti terlihat pada Gambar 4.15.



Gambar 4.15 Akurasi 16 Fitur vs 11 Fitur


Dari Gambar 4.15 dapat dilihat bahwa antara penggunaan 16 fitur dan 11 fitur tidak terlalu berpengaruh untuk algoritma LDA dan RF karena rata-rata akurasi yang didapatkan tetap. Sedangkan untuk rata-rata akurasi KNN dan CART meningkat sebesar 1%. Peningkatan akurasi yang paling tampak adalah pada algoritma SVM sebesar 3%. Perbandingan di atas menunjukkan bahwa proses seleksi fitur cukup berhasil karena dengan mengurangi fitur berbobot rendah dapat meningkatkan performa klasifikasi.

Hasil penghitungan evaluasi model yang lain seperti *recall*, *precision* dan *f1-score* menunjukkan hasil yang hampir sama dengan pengukuran akurasi di atas. Secara umum, terdapat sedikit peningkatan dari penggunaan 11 fitur dibandingkan dengan 16 fitur. Peningkatan yang cukup terlihat terjadi pada algoritma CART dan SVM, sedangkan algoritma yang lain cenderung stagnan. Hasil perbandingan nilai *recall*, *precision* dan *f1-score* antara penggunaan 16 fitur dan 11 fitur hasil seleksi tersaji pada Tabel 4.14.

Tabel 4.14 Nilai *Recall*, *Precision*, *F1-score* Menggunakan 16 Fitur dan 11 Fitur


Algoritma	<i>Recall</i>		<i>Precision</i>		<i>F1-score</i>	
	16 Fitur	11 Fitur	16 Fitur	11 Fitur	16 Fitur	11 Fitur
KNN	0,94	0,94	0,94	0,95	0,93	0,94
LDA	0,9	0,9	0,91	0,9	0,9	0,9
CART	0,83	0,85	0,86	0,86	0,83	0,85
RF	0,87	0,87	0,89	0,89	0,87	0,87
SVM	0,83	0,86	0,85	0,88	0,83	0,86

Adapun untuk nilai AUC-ROC dari penggunaan 16 fitur, KNN mendapatkan 98%, LDA 97%, CART 87%, RF 97% dan SVM mendapatkan 92%. Kurva ROC untuk 16 fitur dapat dilihat pada Gambar 4.16.



Gambar 4.16 Kurva ROC untuk 16 Fitur

Penggunaan 11 fitur hasil dari proses seleksi fitur meningkatkan nilai AUC pada algoritma CART dan RF sebesar 1% dibandingkan dengan penggunaan 16 fitur. Sedangkan untuk algoritma yang lain nilainya sama. Rincian dari perbandingan nilai AUC-ROC tersaji pada Gambar 4.17.



Gambar 4.17 Perbandingan Nilai AUC-ROC pada 16 Fitur dan 11 Fitur

4.4.1.3 Uji Parameter

Dalam penelitian ini juga akan dibandingkan sejauh mana peningkatan performa klasifikasi jika menggunakan hanya salah satu parameter warna atau tekstur, dan menggabungkan antara keduanya. Parameter warna menggunakan tiga fitur dari rata-rata kanal RGB. Sedangkan parameter tekstur menggunakan fitur dari metode GLCM dengan sudut 0° dan jarak 1 piksel. Adapun hasil akurasi klasifikasi dengan hanya menggunakan fitur warna dan metode *10-Fold Cross Validation* tersaji pada Tabel 4.15.

Tabel 4.15 Hasil Akurasi Menggunakan Fitur Warna


	Jumlah K										μ	Med
	1	2	3	4	5	6	7	8	9	10		
KNN	0,94	0,89	0,72	0,94	0,78	0,89	0,83	0,89	0,88	1,00	0,88	0,89
LDA	0,78	0,83	0,78	0,61	0,72	0,78	0,67	0,89	0,82	0,76	0,76	0,78
CART	0,89	0,89	0,72	0,78	0,78	0,78	0,83	0,94	0,88	0,88	0,84	0,84
RF	0,89	0,89	0,72	0,78	0,83	0,78	0,89	0,89	0,88	0,88	0,84	0,88
SVM	0,78	0,83	0,67	0,78	0,83	0,72	0,78	0,83	0,82	0,88	0,79	0,79

Sedangkan untuk klasifikasi menggunakan fitur tekstur (GLCM) dengan metode *10-Fold Cross Validation* tersaji pada Tabel 4.16.

Tabel 4.16 Hasil Akurasi Menggunakan Fitur Tekstur

	Jumlah K										μ	Med
	1	2	3	4	5	6	7	8	9	10		
KNN	0,89	1,00	0,89	1,00	0,94	0,72	0,78	0,94	1,00	0,88	0,90	0,90
LDA	1,00	1,00	0,83	0,83	0,83	0,89	0,89	0,83	0,82	0,88	0,88	0,88
CART	0,89	0,72	0,83	0,89	1,00	0,67	0,83	0,78	0,88	0,76	0,83	0,83
RF	0,94	0,89	0,83	1,00	0,94	0,72	0,83	0,78	0,88	0,88	0,87	0,88
SVM	0,83	0,94	0,94	0,78	0,83	0,78	0,72	0,78	0,88	0,94	0,84	0,83

Dari Tabel 4.15 dan Tabel 4.16 terlihat perbedaan akurasi yang signifikan antara parameter warna dan tekstur hanya terjadi pada algoritma LDA. Sedangkan pada algoritma yang lain hanya ada sedikit perbedaan. Dengan menggabungkan kedua parameter di atas didapatkan peningkatan akurasi antara 2%-13% seperti yang terlihat pada Gambar 4.18. Hal ini menunjukkan bahwa penggabungan dua parameter di atas menyebabkan peningkatan performa klasifikasi yang cukup signifikan.



Gambar 4.18 Akurasi Fitur Warna vs Fitur Tekstur vs 11 Fitur


Untuk nilai *recall*, *precision* dan *f1-score* antara parameter warna dan tekstur menunjukkan hasil yang identik dengan hasil akurasi di atas seperti yang tersaji pada Tabel 4.17.

Tabel 4.17 Nilai *Recall*, *Precision*, *F1-score* Tiap Parameter

	Recall			Precision			F1-Score		
	Warna	Tekstur	11 Fitur	Warna	Tekstur	11 Fitur	Warna	Tekstur	11 Fitur
KNN	0,86	0,9	0,94	0,9	0,91	0,95	0,84	0,9	0,94
LDA	0,73	0,88	0,9	0,73	0,89	0,9	0,7	0,87	0,9
CART	0,82	0,79	0,85	0,84	0,8	0,86	0,81	0,79	0,85
RF	0,83	0,84	0,87	0,84	0,87	0,89	0,81	0,84	0,87
SVM	0,75	0,81	0,86	0,77	0,84	0,88	0,72	0,81	0,86

Secara umum, nilai pada parameter tekstur lebih bagus daripada nilai parameter warna untuk ketiga evaluasi tersebut. Bahkan untuk algoritma LDA selisih nilai antara parameter warna dan tekstur mencapai 17%.. Dengan menggabungkan kedua parameter di atas didapatkan peningkatan *recall* antara 2%-17%, peningkatan *precision* antara 1%-17% dan peningkatan *f1-score* antara 3%-20%.


Adapun untuk AUC-ROC, nilai yang didapatkan dari parameter warna yaitu: KNN mendapatkan 97%, LDA 90%, CART 89%, RF 97% dan SVM 91%. Sedangkan untuk parameter tekstur, KNN mendapatkan nilai 97%, LDA 97%, CART 86%, RF 95% dan SVM sebesar 90%. Secara umum nilai yang didapatkan dari parameter tekstur dan parameter warna seimbang. Perbedaan yang signifikan hanya terdapat pada algoritma LDA dimana nilai parameter tekstur lebih besar 7% daripada parameter warna. Sebaliknya, untuk nilai AUC parameter warna sedikit lebih baik pada algoritma CART, RF dan SVM. Dengan menggabungkan kedua parameter tekstur dan warna nilai AUC meningkat antara 1%-7%. Peningkatan nilai AUC dapat dilihat pada Gambar 4.19.



Gambar 4.19 Nilai AUC Tiap Parameter

4.4.2 Data Testing

Untuk menguji data *testing*, proses klasifikasi hanya menggunakan metode KNN sebagai algoritma terbaik pada data *training*. Dengan parameter yang sama pada data *training*, uji model dilakukan pada 43 data *testing*. Hasilnya model ini mampu mengklasifikasikan 40 data dengan benar. Dengan kata lain mendapatkan nilai akurasi sebesar 93%. Hasil ini cukup bagus dan mampu merepresentasikan model dengan tepat, karena pada data *training* menghasilkan rata-rata nilai akurasi sekitar 94-95%. Hasil klasifikasi secara lengkap tersaji pada Gambar 4.20 dalam format *Confusion Matrix*.



Gambar 4.20 Confusion Matrix dari Data Testing

Dari gambar 4.20 di atas, terlihat bahwa ada 43 data *testing* yang terbagi menjadi 3 (tiga) kelas. Kelas 2 terdiri dari 19 data, Kelas 3 terdapat 12 data dan Kelas 4 juga terdiri dari 12 data. Hasil klasifikasi menunjukkan bahwa ada tiga data yang salah diprediksi oleh model. Data tersebut seharusnya termasuk Kelas 2 namun salah diprediksi sebagai Kelas 4. Dengan hasil tersebut kita dapat menghitung nilai *precision*, *recall* dan *model evaluation* lainnya yang dijabarkan pada Tabel 4.18.

Tabel 4.18 Model Evaluation Data *Testing*

Kelas	Precision	Recall	F1-score	Support
2	1,00	0,84	0,91	19
3	1,00	1,00	1,00	12
4	0,80	1,00	0,89	12

Dari Tabel 4.18 di atas terlihat bahwa model yang terbentuk sudah cukup baik dalam mengklasifikasikan data *testing*. Nilai *precision*, *recall* dan *F1-score* cukup tinggi dan seimbang. Sehingga kesimpulan yang dapat diambil bahwa model ini sudah bisa digunakan dalam mengklasifikasikan kekuatan kayu.

Halaman ini sengaja dikosongkan

BAB 5

KESIMPULAN

Sebagai penutup dari tesis ini, akan disajikan kesimpulan dari hasil penelitian dan pembahasan pada bab sebelumnya, serta saran yang didasarkan pada hasil kesimpulan. Saran dalam hasil penelitian ini diharapkan dapat bermanfaat dan menjadi masukan bagi pihak lain yang ingin melanjutkan penelitian terkait dengan analisis kekuatan kayu berdasarkan pengolahan citra.

5.1 Kesimpulan

Penelitian ini bertujuan untuk memperoleh cara pengidentifikasian kekuatan kayu yang mempunyai akurasi tinggi, mudah, murah, serta tidak bersifat destruktif terhadap kayu uji dengan memanfaatkan teknologi pengolahan citra dan *machine learning*. Berdasarkan hasil analisis, maka kesimpulan yang dapat diambil dari penelitian ini adalah sebagai berikut:

1. Perpaduan antara parameter warna dan tekstur (GLCM) pada citra kayu cukup baik dalam mengklasifikasikan kekuatan kayu. Dengan menggabungkan kedua parameter tersebut peningkatan akurasi sebesar 2-13% dibandingkan ketika menggunakan kedua parameter secara terpisah.
2. Dengan menggunakan semua fitur dan lima algoritma klasifikasi yaitu LDA, KNN, CART, RF, dan SVM didapatkan rata-rata akurasi yang cukup tinggi yaitu di atas 85%. Dengan perincian KNN mendapatkan rata-rata akurasi 94%, LDA sebesar 91%, RF sebesar 89%, CART mendapatkan 86% dan SVM sebesar 85%.
3. Dengan menggunakan metode seleksi fitur yaitu RFECV berhasil menghilangkan lima fitur dengan bobot terendah. Pengaruh seleksi fitur terhadap performa klasifikasi berbeda-beda untuk tiap algoritma. Untuk algoritma LDA dan RF tidak berpengaruh sama sekali karena rata-rata akurasi yang didapatkan tetap. Sedangkan untuk rata-rata akurasi KNN dan CART meningkat sebesar 1%. Peningkatan akurasi yang paling tampak adalah pada algoritma SVM sebesar 3%.

4. Metode KNN merupakan yang terbaik pada penelitian ini di hampir semua model evaluasi, di antaranya: *accuracy*, *precision*, *recall*, *f1-score* dan AUC. Akurasi yang didapatkan sebesar 95%, *precision* sebesar 95%, *recall* sebesar 94%, *f1-score* sebesar 94% dan nilai AUC sebesar 98%.
5. Pada data *testing*, metode KNN dapat mengklasifikasikan 40 data dengan benar dari 43 data yang digunakan. Sehingga metode ini dapat digunakan sebagai alternatif untuk mengklasifikasikan kelas kayu yang sederhana, mudah dan murah.

5.2 Saran

Penelitian ini dilakukan dengan beberapa batasan antara lain menggunakan kayu lokal yang sering digunakan untuk bahan baku pembuatan rumah dan mebel. Oleh karena itu, dengan adanya keterbatasan ini maka disarankan pada penelitian selanjutnya untuk menggunakan *database* kayu yang lebih luas seperti kayu hutan atau jenis kayu lain yang belum dimanfaatkan secara maksimal. Dengan demikian manfaat penelitian bisa berdampak lebih luas, karena tidak terbatas untuk penggunaan mebel dan bangunan saja.

Dengan adanya *database* yang lebih besar, disarankan pula untuk menggunakan algoritma *deep learning*. Karena diklaim lebih tangguh khususnya untuk memperhitungkan data yang tidak eksak, seperti: bahasa, suara, atau gambar. Syarat utama agar hasil *deep learning* bisa maksimal adalah menggunakan data *training* dalam jumlah yang sangat besar sehingga juga membutuhkan kekuatan komputasi yang tinggi. Oleh karena itu, untuk proses *deep learning* biasanya disarankan menggunakan GPU (*Graphic Processing Unit*) karena mampu menangani instruksi dalam jumlah yang lebih besar dan lebih cepat dibandingkan dengan CPU (*Central Processing Unit*)

DAFTAR PUSTAKA

- [1] Asmara, R.A., Hamidi, Y. and Puspitasari, D. (2017) 'Tropical hardwood species identification based on first order statistical moment of cross section images color and texture extraction using GLCM', International Conference on Information & Communication Technology and System, Surabaya.
- [2] Badan Standarisasi Nasional (2002) Metode Pengujian Berat Jenis Kayu dan Bahan dari Kayu dengan Cara Pencelupan Dalam Air, SNI 03-3958-2002.
- [3] Bardak, T. and Bardak, S. (2017) 'Prediction of Wood Density by Using RGB Color and Fuzzy Logic Techniques', Journal of Polytechnic, vol. 20(4), pp. 979-984.
- [4] Breiman, L. (1996) 'Bagging Predictors', Machine Learning, vol. 24, no. 2, pp. 123-140.
- [5] Breiman, L. (2001) 'Random Forests', Machine Learning 45, pp. 5-32.
- [6] Çetiner, I., Var, A. and Cetiner, H. (2016) 'Classification of Knot Defect Types Using Wavelets and KNN', Elektronika ir Elektrotehnika, vol. 22, pp. 67-72.
- [7] Coelho, L.P. (2013) 'Mahotas: Open Source Software for Scriptable Computer Vision', Journal of Open Research Software, vol. 1, p. e3.
- [8] Dirjen Kehutanan (1976) Vademecum Kehutanan Indonesia.
- [9] Doraisamy, S., Golzari, S., Mohd. Norowi, N., Sulaiman, N.n. and Udzir, N. (2008) 'A Study on Feature Selection and Classification Techniques for Automatic Genre Classification of Traditional Malay Music', International Conference on Music Information Retrieval (ISMIR), Philadelphia, 331-336.
- [10] Filho, Oliveira, Britto and Sabourin (2010) 'Forest Species Recognition Using Color-Based Features', International Conference on Pattern Recognition, Istanbul.
- [11] Guyon, I. and Elisseeff, A. (2003) 'An Introduction to Variable and Feature Selection', Journal of Machine Learning Research 3, pp. 1157-1182.
- [12] Guyon, I., Weston, J., Barnhill, S. and Vapnik, V. (2002) 'Gene selection for cancer classification using support vector machines', Machine Learning, vol. 46, pp. 389-422.
- [13] Haygreen, J.G. and Bowyer, J.L. (1993) Hasil Hutan dan Ilmu Kayu. Terjemahan Sutjipto A. Hadikusumo, Yogyakarta: Gajah Mada University Press.
- [14] Hidayati, F. and Siagian, P. (2012) 'Struktur dan Sifat Kayu Trembesi (Samanea Saman MERR)', Prosiding Seminar Nasional Mapeki, vol. 13, pp. 228-232.
- [15] Hongbo, M., Dawei, Q. and Mingming, Z. (2010) 'Study of Wood Defects Recognition Based on Image Processing', International Conference on Computer and Communication Technologies in Agriculture Engineering, pp. 40-43.

- [16] Hsu, C.W. and Lin, C.J. (2002) 'A Comparison of Methods for Multiclass Support Vector Machines', *IEEE Transactions on Neural Network*, vol. 13(2), pp. 415-425.
- [17] Maharsi, D.N., Halomoan, J. and Atmaja, R.D. (2015) 'Klasifikasi Serat Miring pada Kayu Menggunakan Ekstraksi Ciri Statistik Berdasarkan Pada Pengolahan Citra', *e-Proceeding of Engineering*, vol. 2, No. 1, pp. 209-2016.
- [18] Mandang, Y.I. and Pandit (1997) *Pedoman Identifikasi Kayu di Lapangan*, Bogor: Yayasan Prosea.
- [19] Martawijaya, A., Kartasujana, I., Kadir, K. and Prawira, S.A. (2005) *Atlas Kayu Indonesia Jilid I*, Bogor: Badan Litbang Kehutanan, Departemen Kehutanan.
- [20] Martawijaya, A., Kartasujana, I., Kadir, K. and Prawira, S.A. (2014) *Atlas Kayu Indonesia Jilid IV*, Bogor: Badan Litbang Kehutanan, Kementerian Kehutanan.
- [21] Martawijaya, A., Kartasujana, I., Mandang, Y.I., Kadir, K. and Prawira, S.A. (1989) *Atlas Kayu Indonesia Jilid II*, Bogor: Badan Litbang Kehutanan, Departemen Kehutanan.
- [22] Novakovic, J. (2010) 'The Impact of Feature Selection on the Accuracy of Naive Bayes Classifier', *Telecommunication Forum (TELFOR)*, Belgrade, 1113-1116.
- [23] Nugroho, A.S. (2008) 'Support Vector Machine: Paradigma Baru dalam Softcomputing', *Konferensi Nasional Sistem dan Informatika*, pp. 92-99.
- [24] Oey, D.S. (1990) *Berat Jenis dari Jenis-Jenis Kayu Indonesia dan Pengertian Beratnya Kayu untuk Keperluan Praktek*. Pengumuman No. 3, Bogor: Lembaga Penelitian Hasil Hutan.
- [25] P3HH-Pusat Penelitian dan Pengembangan Hasil Hutan (2008) *Petunjuk Praktis Sifat-Sifat Dasar Jenis Kayu Indonesia*, Indonesian Sawmill and Woodworking Association (ISWA).
- [26] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. and Duchesnay, E. (2011) 'Scikit-learn: Machine Learning in Python', *Journal of Machine Learning Research*, vol. 12, pp. 2825-2830.
- [27] Pramunendar, R.A., Supriyanto, C., Novianto, D.H., Yuwono, I.N., Shidik, G.F. and Andono, P.N. (2013) 'A classification method of coconut wood quality based on GLCM', *International Conference on Robotics, Biomimetics, Intelligent Computational Systems*, Yogyakarta.
- [28] Purwanto, D. (2012) 'Akasia Mangium Wood (Acacia Mangium, Willd) Used for Furniture', *Jurnal Riset Industri Hasil Hutan*, vol. 4, pp. 1-8.
- [29] Qayyum, R., Kamal, K., Zafar, T. and Mathavan, S. (2016) 'Wood defects classification using GLCM based features and PSO trained neural network', *International Conference on Automation and Computing (ICAC)*, Colchester, UK.
- [30] Quinlan, R. (1986) 'Induction of Decision Trees', *Machine Learning* 1, pp. 81-106.

- [31] Ruffinatto, F., Crivellaro, A. and Wiedenhoeft, A.C. (2015) 'Review of Macroscopic Features for Hardwood and Softwood Identification and AProposal for ANew Character List', IAWA Journal, vol. 36(2), pp. 208-241.
- [32] Siagian, R.Y. (2011) 'Klasifikasi Parket Kayu Jati Menggunakan Metode Support Vector Machine (SVM)', Jurusan Teknik Informatika, Fakultas Teknologi Industri, Universitas Gunadarma.
- [33] Sucipto, T. (2009) 'Penentuan Air dalam Rongga Sel Kayu', Fakultas Pertanian, Universitas Sumatera Utara.
- [34] Suprpti, S., Djarwanto and Hudiansyah (2004) 'Ketahanan Lima Jenis Kayu Terhadap Beberapa Jamur Perusak Kayu', Jurnal Penelitian Hasil Hutan, vol. 22, pp. 239-246.
- [35] Xie, Z., Liu, G., He, C. and Wen, Y. (2010) 'Texture Image Retrieval Based on Gray Level Co-Occurrence Matrix and Singular Value Decomposition', International Conference on Multimedia Technology, pp. 1-3.
- [36] Zhang, F., L Kaufman, H., Deng, Y. and Drabier, R. (2013) 'Recursive SVM biomarker selection for early detection of breast cancer in peripheral blood', BMC Medical Genomics.

Halaman ini sengaja dikosongkan


LAMPIRAN

Lampiran I Citra Hasil *Pre-Processing*


- Kayu Akasia



- Kayu Jati



- Kayu Mahoni



- Kayu Trembesi




- Kayu Waru



- Kayu Sengon Laut



- Kayu Sengon Tekek



Lampiran II Nilai Ekstraksi Fitur Kanal RGB

No	Kelas Kuat / Label	Kayu	Nilai Fitur		
			Blue	Green	Red
1	II	Akasia	116,5900	128,6096	147,0843
2			91,8083	103,3892	123,3899
3			107,5822	116,1105	130,8676
4			122,1203	144,7936	180,5718
5			99,7112	111,4398	129,4228
6			107,9889	121,7119	141,9113
7			126,4947	143,5926	175,8962
8			135,2266	148,4245	170,2559
9			112,5831	106,4780	109,8983
10			122,9533	137,4646	166,8602
11			141,6453	150,0543	164,9391
12			112,3558	116,2301	128,5267
13			110,5659	105,7219	111,7970
14			148,0326	147,2915	152,7695
15			103,7959	122,9463	148,6193
16			110,0935	122,2728	139,5382
17			142,4674	146,6335	156,8632
18			114,0535	130,1002	159,2175
19			99,7045	113,2129	131,3859
20			105,5875	119,6947	141,1535
21		Jati	112,7519	120,8870	134,9778
22			114,8552	125,0953	138,4178
23			118,3648	132,2355	149,0252
24			123,5879	130,9039	143,3154
25			121,8242	135,2149	153,2918
26			138,4136	141,8472	152,8317
27			106,6862	116,4295	131,8865
28			135,8054	146,0549	160,2412
29			104,8540	116,3583	134,3029
30			149,9429	150,9408	158,1135
31			100,7425	115,8683	139,3748
32			115,8385	129,5182	159,2299
33			147,0401	155,3254	170,6637
34			97,1448	116,2153	142,4210
35			126,6627	140,2889	167,9166
36			131,6826	149,0713	175,0197
37			116,9724	136,7501	169,1319
38			74,8708	84,9978	102,2197
39			150,7026	157,7444	168,9529
40			119,7163	134,3169	162,5290

No	Kelas Kuat / Label	Kayu	Nilai Fitur		
			Blue	Green	Red
41	II	Jati	120,3926	118,1853	125,6301
42			99,5862	117,6322	145,8636
43			109,6503	118,8624	132,9899
44			144,7104	146,8688	155,7188
45			119,6306	111,8329	114,9655
46			89,7737	103,0913	126,2554
47			95,8029	117,2852	146,6738
48			117,8780	121,5972	132,6246
49		Mahoni	103,6098	111,1324	127,3912
50			110,7713	118,6708	136,1393
51			115,6973	134,9694	169,6639
52			116,9786	131,1163	159,5433
53			103,6091	117,0083	138,3155
54			89,2460	103,2636	126,8372
55			123,3260	131,9292	147,0572
56			115,8474	134,4827	167,9844
57			102,4582	118,0588	145,4223
58			124,1228	141,3313	172,7514
59			110,6997	109,4511	117,5703
60			114,0924	128,7090	157,6676
61			128,4683	129,6901	138,4297
62			119,5136	123,7080	134,0289
63			113,6313	128,5721	157,6213
64			122,3672	137,6340	165,6705
65			127,3821	140,2506	165,5268
66			122,8498	135,1369	161,0760
67			107,8382	117,2746	132,2969
68			135,1756	149,9042	173,9656
69			113,0523	108,8838	114,3119
70			113,5801	121,1739	138,7897
71			125,7049	129,1306	139,4342
72			116,8948	134,4706	164,6404
73			120,9469	121,7204	131,4059
74			111,5256	129,3772	163,3726
75			113,5221	105,8902	108,7839
76			79,5947	92,3012	115,1895
77	III	Trembesi	142,7053	143,9283	154,6834
78			112,3701	106,9945	111,5219
79			118,4446	136,0051	167,4390
80			126,8086	140,8962	169,4114
81			107,6328	121,1381	142,9020
82			113,8587	105,9703	108,4549

No	Kelas Kuat / Label	Kayu	Nilai Fitur		
			Blue	Green	Red
83	III	Trembesi	113,2108	107,2250	111,8985
84			117,3987	134,3406	165,8046
85			124,9158	135,9414	159,5930
86			114,7168	128,7214	152,7579
87			122,7777	138,4358	170,3623
88			106,8650	104,7138	112,2646
89			100,6464	117,8969	139,2384
90			146,7633	148,7372	156,7966
91			142,0216	150,2342	163,6564
92			107,7099	109,6219	121,8315
93			148,7343	147,5977	154,5400
94			131,3478	148,3234	174,0970
95			89,0635	103,9574	127,7091
96			117,6201	109,9741	113,3102
97			156,6764	154,1572	159,4462
98			148,6064	151,2235	160,1108
99			115,3941	130,6229	161,9692
100			125,2376	135,2144	149,3309
101			147,0106	156,0917	169,9113
102			143,4148	145,3497	155,4816
103			88,1476	102,7405	127,4685
104			119,4527	136,4569	169,4612
105		Waru	125,9050	119,1192	122,7277
106			114,7309	131,4167	160,9524
107			107,1018	119,7902	140,8732
108			126,9783	143,0577	172,5856
109			112,3923	115,5875	127,9978
110			88,6787	97,3228	115,3592
111			109,3448	117,8030	133,2397
112			109,6133	126,0368	147,8340
113			140,5656	149,4002	161,9145
114			120,1070	130,8150	154,3029
115			150,5905	153,5096	164,0863
116			100,1310	119,5874	147,9000
117			127,0742	142,9478	173,8408
118			146,6455	152,5339	163,4985
119			155,2045	157,2861	166,3150
120			122,7906	130,3363	141,0613
121			131,3427	123,1652	126,3909
122			124,5014	137,1939	162,6755
123			129,3693	126,9775	132,3778
124			117,4361	123,1482	135,9648

No	Kelas Kuat / Label	Kayu	Nilai Fitur		
			Blue	Green	Red
125	III	Waru	127,9218	122,0418	126,0493
126			133,1159	150,9528	179,8191
127			119,5960	132,9047	158,3494
128			117,5512	127,3782	142,7780
129			131,2882	145,6872	173,8383
130			94,9836	105,3126	124,9707
131	IV	Sengon Laut	122,2227	133,2913	159,3145
132			142,3546	146,5288	157,2975
133			159,8247	156,1985	161,1431
134			125,4641	123,2551	130,0898
135			104,4269	122,1781	145,2537
136			87,8639	98,1709	116,2778
137			118,2098	114,9028	123,1076
138			112,8031	108,7198	114,3740
139			113,0766	118,9875	131,7593
140			116,5559	119,9962	130,6776
141			111,7394	105,1484	109,3143
142			107,0496	118,8199	137,6934
143			113,2362	131,8950	164,2441
144			85,0963	100,7118	129,8861
145			153,1919	149,8883	153,7190
146			114,4379	122,2894	136,3443
147			114,6148	110,5928	117,2175
148			110,4466	102,6797	105,9375
149			117,8121	126,4347	140,7020
150			111,4533	125,9010	143,5013
151			135,7677	147,9419	167,7485
152			127,4367	142,2949	169,9568
153			88,2375	104,7730	133,5317
154			142,5675	153,7647	172,3361
155		Sengon Tekek	116,3507	107,9448	110,1621
156			155,2774	156,8267	164,1443
157			94,5951	107,3643	127,6438
158			121,4576	117,0408	123,4180
159			151,4080	153,9829	163,4372
160			111,7280	123,1726	146,3132
161			88,2976	99,0173	119,5095
162			135,4156	140,9517	152,3674
163			121,0223	132,8804	159,7346
164			121,5101	129,1888	142,6655
165			122,6998	134,5612	160,1169
166			132,9953	146,5119	167,9340

No	Kelas Kuat / Label	Kayu	Nilai Fitur		
			Blue	Green	Red
167	IV	Sengon Tekek	148,0146	156,3862	170,0565
168			144,6491	150,9282	163,2167
169			92,6127	107,5225	133,9113
170			120,3368	120,4866	128,8800
171			111,5883	115,8417	128,6928
172			92,4375	109,9174	137,1947
173			115,8677	131,0853	162,2677
174			118,9877	111,0038	113,6575
175			116,9536	125,3414	140,0649
176			109,8111	109,4691	118,6504
177			151,6959	151,1275	159,0523
178			156,4732	161,3127	171,5842

Lampiran III Nilai Ekstraksi Fitur Kanal GLCM

No	Kelas Kuat / Label	Kayu	Nilai Fitur GLCM												
			ASM	Cont.	Corr.	Var.	IDM	Σ Avg.	Σ Var.	Σ Entr.	Entr.	Δ Var.	Δ Entr.	MoC I	MoC II
1	II	Akasia	0,0028	11,8076	0,9523	123,7765	0,3573	265,4915	483,2984	6,4711	9,1153	0,0010	2,8208	-0,3393	0,9834
2			0,0008	34,4671	0,9598	429,1914	0,2388	216,0505	1682,2987	7,3825	10,8571	0,0005	3,5754	-0,3037	0,9881
3			0,0009	46,1195	0,9123	263,1158	0,2142	239,1071	1006,3437	7,0036	10,6907	0,0004	3,7833	-0,2302	0,9636
4			0,0014	31,9668	0,9494	315,9107	0,2890	305,8553	1231,6758	7,1045	10,2647	0,0006	3,3714	-0,3229	0,9866
5			0,0011	13,5411	0,9901	684,0247	0,3341	230,9310	2722,5578	7,6489	10,4337	0,0008	2,9505	-0,4326	0,9980
6			0,0021	14,3890	0,9534	154,5270	0,3161	252,3500	603,7191	6,6463	9,5163	0,0008	3,0100	-0,3202	0,9841
7			0,0011	41,6554	0,9376	333,7138	0,2426	302,6757	1293,1997	7,1415	10,5756	0,0004	3,6083	-0,2841	0,9808
8			0,0012	20,2851	0,9850	676,5717	0,3469	306,9738	2686,0015	7,6403	10,5043	0,0007	3,1106	-0,4197	0,9978
9			0,0024	7,2922	0,9844	233,2409	0,4235	216,3980	925,6713	6,9582	9,2973	0,0013	2,5481	-0,4413	0,9969
10			0,0019	17,2837	0,9645	243,6139	0,3590	289,2666	957,1720	6,9871	9,7960	0,0008	2,9900	-0,3674	0,9919
11			0,0025	17,5275	0,9666	262,3557	0,3955	307,1274	1031,8953	6,9642	9,5234	0,0009	2,9010	-0,4053	0,9946
12			0,0022	20,0387	0,9365	157,8022	0,3229	238,9897	611,1702	6,6522	9,6239	0,0008	3,1466	-0,3041	0,9795
13			0,0019	11,6676	0,9781	266,4149	0,3632	216,1753	1053,9920	7,0349	9,7037	0,0010	2,8417	-0,3947	0,9952
14			0,0042	5,3717	0,9709	92,1993	0,4536	298,0165	363,4254	6,2745	8,4091	0,0012	2,3626	-0,4095	0,9916
15			0,0011	35,5885	0,9368	281,4870	0,2513	256,8872	1090,3594	7,0883	10,5008	0,0005	3,5660	-0,2816	0,9793
16			0,0019	14,7038	0,9631	199,4485	0,3347	252,0623	783,0902	6,8109	9,6259	0,0009	2,9703	-0,3482	0,9883
17			0,0033	7,0134	0,9712	121,8557	0,4214	298,5357	480,4092	6,4810	8,7919	0,0010	2,5183	-0,3993	0,9924
18			0,0011	21,6949	0,9785	503,9631	0,3180	273,9723	1994,1573	7,5155	10,5605	0,0006	3,1983	-0,3813	0,9958
19			0,0017	20,9469	0,9413	178,4629	0,2848	234,2190	692,9046	6,7429	9,8422	0,0008	3,2392	-0,2926	0,9794
20			0,0011	17,4077	0,9904	908,4479	0,2970	248,9658	3616,3839	7,5231	10,5264	0,0007	3,1431	-0,3904	0,9965
21		Jati	0,0017	18,2588	0,9617	238,5013	0,3160	248,3846	935,7463	6,9159	9,8727	0,0008	3,1003	-0,3361	0,9877
22			0,0018	17,3379	0,9535	186,5970	0,3081	255,8735	729,0502	6,7852	9,7477	0,0007	3,0989	-0,3204	0,9845
23			0,0024	10,6458	0,9663	157,8907	0,3610	271,3254	620,9168	6,6517	9,2547	0,0010	2,7870	-0,3664	0,9900
24			0,0021	14,2796	0,9602	179,6183	0,3335	267,6249	704,1935	6,7728	9,5667	0,0008	2,9507	-0,3470	0,9878
25			0,0029	10,1088	0,9593	124,1951	0,3805	278,1736	486,6715	6,4802	9,0120	0,0010	2,7199	-0,3603	0,9875
26			0,0030	11,6495	0,9716	204,9714	0,4365	289,5323	808,2363	6,8443	9,2348	0,0011	2,6743	-0,4223	0,9954
27			0,0025	10,2724	0,9693	167,2586	0,3747	239,8903	658,7618	6,7152	9,2839	0,0010	2,7497	-0,3791	0,9913
28			0,0044	5,9948	0,9712	104,2642	0,4695	298,2676	411,0622	6,3635	8,4526	0,0013	2,3612	-0,4271	0,9934
29			0,0016	15,4112	0,9760	321,3830	0,3200	240,7868	1270,1207	7,1259	10,0021	0,0009	3,0301	-0,3705	0,9933
30			0,0066	4,3028	0,9590	52,4648	0,4853	306,0313	205,5562	5,8716	7,8387	0,0014	2,2316	-0,3959	0,9874
31			0,0015	12,9509	0,9805	331,6986	0,3285	242,3285	1313,8436	7,1387	9,9238	0,0009	2,9379	-0,3861	0,9950
32			0,0015	22,4141	0,9655	325,1460	0,3078	273,6986	1278,1700	7,1126	10,1619	0,0007	3,2111	-0,3414	0,9900
33			0,0044	7,4179	0,9564	84,9852	0,4227	317,9416	332,5231	6,1971	8,4914	0,0012	2,5320	-0,3710	0,9862
34			0,0011	25,3016	0,9708	433,9766	0,2827	243,7456	1710,6049	7,3632	10,5578	0,0006	3,3412	-0,3438	0,9923

No	Kelas Kuat / Label	Kayu	Nilai Fitur GLCM												
			ASM	Cont.	Corr.	Var.	IDM	Σ Avg.	Σ Var.	Σ Entr.	Entr.	Δ Var.	Δ Entr.	MoC I	MoC II
35	II	Jati	0,0020	14,2978	0,9677	221,4071	0,3585	293,9933	871,3305	6,9035	9,6196	0,0007	2,9079	-0,3739	0,9921
36			0,0026	18,5238	0,9660	274,1506	0,3878	309,8067	1078,0784	6,8301	9,3852	0,0009	2,8598	-0,3925	0,9933
37			0,0012	36,2552	0,9622	481,0048	0,2803	288,5219	1887,7641	7,3244	10,5824	0,0005	3,4476	-0,3302	0,9907
38			0,0009	17,1084	0,9946	1572,1341	0,3158	177,9183	6271,4279	7,8215	10,7489	0,0007	3,1016	-0,4273	0,9983
39			0,0041	6,5475	0,9721	117,3343	0,4623	320,6539	462,7896	6,3995	8,5179	0,0012	2,4083	-0,4264	0,9934
40			0,0018	16,4721	0,9662	243,7718	0,3389	282,1867	958,6151	6,9621	9,7900	0,0008	3,0170	-0,3613	0,9910
41			0,0033	6,4469	0,9751	129,5569	0,4321	241,3208	511,7806	6,5039	8,7508	0,0013	2,4908	-0,4139	0,9939
42			0,0012	28,6636	0,9552	319,8278	0,2564	248,1487	1250,6476	7,1271	10,4326	0,0006	3,4378	-0,3029	0,9861
43			0,0020	14,0341	0,9640	194,7621	0,3510	244,1003	765,0143	6,8230	9,5795	0,0009	2,9213	-0,3589	0,9897
44			0,0026	10,2132	0,9785	237,2700	0,4310	298,5360	938,8669	6,9099	9,2896	0,0010	2,6478	-0,4308	0,9962
45			0,0021	14,1482	0,9610	181,3885	0,3444	227,3167	711,4057	6,7760	9,5698	0,0008	2,9600	-0,3472	0,9892
46			0,0008	37,7609	0,9514	388,7560	0,2346	216,9414	1517,2630	7,3165	10,8447	0,0006	3,6307	-0,2884	0,9853
47			0,0013	15,6822	0,9742	303,4743	0,3046	247,3266	1198,2149	7,1366	10,0742	0,0008	3,0734	-0,3612	0,9932
48			0,0022	15,4408	0,9487	150,4623	0,3329	249,0016	586,4082	6,6380	9,4739	0,0009	2,9906	-0,3256	0,9828
49		Mahoni	0,0021	10,7028	0,9753	216,9977	0,3824	230,2816	857,2879	6,8952	9,4710	0,0011	2,7795	-0,3960	0,9945
50			0,0022	19,0198	0,9402	158,9924	0,3176	246,0431	616,9499	6,6220	9,5794	0,0007	3,1369	-0,3028	0,9803
51			0,0010	23,3798	0,9815	630,5166	0,2988	286,2850	2498,6867	7,6555	10,7215	0,0005	3,2613	-0,3910	0,9967
52			0,0021	13,3658	0,9720	238,7733	0,3770	276,0350	941,7274	6,9719	9,6253	0,0009	2,8463	-0,3910	0,9939
53			0,0011	25,5128	0,9554	286,3858	0,2614	243,6501	1120,0304	7,1074	10,3662	0,0006	3,3762	-0,3075	0,9865
54			0,0014	30,5712	0,9223	196,6902	0,2418	217,3939	756,1894	6,8086	10,2130	0,0006	3,5112	-0,2508	0,9689
55			0,0028	11,0305	0,9534	118,2683	0,3507	270,9594	462,0429	6,4375	9,0819	0,0009	2,8115	-0,3355	0,9837
56			0,0020	15,3605	0,9636	211,0957	0,3574	284,7578	829,0222	6,8829	9,6317	0,0008	2,9431	-0,3664	0,9912
57			0,0010	51,2889	0,8759	206,5742	0,1929	248,9475	775,0079	6,8106	10,6089	0,0004	3,8864	-0,1897	0,9394
58			0,0015	22,2450	0,9567	257,1618	0,3080	297,5498	1006,4021	7,0107	10,0791	0,0006	3,2171	-0,3278	0,9878
59			0,0018	11,9942	0,9769	259,6032	0,3526	224,0686	1026,4187	7,0324	9,7374	0,0009	2,8753	-0,3883	0,9947
60			0,0016	21,4339	0,9730	397,4559	0,3248	271,4322	1568,3899	7,2133	10,1876	0,0007	3,1668	-0,3635	0,9927
61			0,0021	15,4966	0,9563	177,3788	0,3369	264,3561	694,0186	6,7507	9,6014	0,0008	3,0085	-0,3352	0,9865
62			0,0015	20,6427	0,9590	251,8340	0,3088	252,6666	986,6933	7,0055	10,0256	0,0008	3,1685	-0,3350	0,9878
63			0,0016	19,1590	0,9661	282,2044	0,3355	271,1281	1109,6587	7,0826	9,9837	0,0008	3,0919	-0,3619	0,9917
64			0,0010	23,5764	0,9785	547,4338	0,3042	288,5694	2166,1588	7,5764	10,6452	0,0006	3,2458	-0,3834	0,9962
65			0,0019	17,8763	0,9653	257,6498	0,3481	292,6530	1012,7229	7,0075	9,8419	0,0008	3,0386	-0,3651	0,9918
66			0,0019	17,3321	0,9623	229,8566	0,3427	282,9754	902,0942	6,9316	9,7620	0,0008	3,0275	-0,3579	0,9906
67			0,0014	14,1821	0,9791	339,6252	0,3312	241,3968	1344,3186	7,2159	10,0114	0,0008	2,9828	-0,3915	0,9953
68			0,0027	11,9632	0,9727	218,9001	0,4019	310,8369	863,6373	6,8405	9,3249	0,0009	2,7393	-0,4058	0,9946
69			0,0015	12,5409	0,9837	385,0027	0,3718	221,9540	1527,4698	7,3080	9,9966	0,0010	2,8828	-0,4170	0,9968
70			0,0018	10,9843	0,9827	317,6062	0,3469	251,1709	1259,4406	7,1148	9,7930	0,0009	2,8503	-0,4005	0,9957

No	Kelas Kuat / Label	Kayu	Nilai Fitur GLCM												
			ASM	Cont.	Corr.	Var.	IDM	Σ Avg.	Σ Var.	Σ Entr.	Entr.	Δ Var.	Δ Entr.	MoC I	MoC II
71	II	Mahoni	0,0022	11,3771	0,9673	173,8340	0,3633	263,6520	683,9589	6,7335	9,3851	0,0010	2,8302	-0,3668	0,9911
72			0,0015	19,9594	0,9699	331,8418	0,3381	282,9957	1307,4080	7,1867	10,0996	0,0008	3,0999	-0,3706	0,9930
73			0,0017	12,6466	0,9751	253,9907	0,3422	249,0985	1003,3161	6,9720	9,7232	0,0008	2,9111	-0,3754	0,9933
74			0,0014	23,5619	0,9604	297,9156	0,2935	275,0295	1168,1005	7,1272	10,2144	0,0006	3,2412	-0,3369	0,9898
75			0,0016	10,6608	0,9879	439,1943	0,3784	215,2511	1746,1165	7,3829	9,9666	0,0010	2,7789	-0,4400	0,9978
76			0,0008	20,6534	0,9909	1135,2981	0,2941	195,3047	4520,5389	7,7270	10,7846	0,0007	3,2351	-0,4000	0,9973
77	III	Trembesi	0,0030	8,3715	0,9700	139,4906	0,3891	294,1091	549,5908	6,5480	8,9939	0,0010	2,6357	-0,3824	0,9910
78			0,0021	10,8811	0,9789	258,2388	0,3653	217,9508	1022,0743	7,0059	9,6410	0,0010	2,8105	-0,3974	0,9953
79			0,0015	20,5671	0,9644	288,5614	0,3228	286,8028	1133,6787	7,0926	10,0941	0,0007	3,1602	-0,3472	0,9907
80			0,0023	15,1825	0,9579	180,4313	0,3541	295,6588	706,5428	6,7395	9,4992	0,0009	2,9520	-0,3492	0,9885
81			0,0027	12,6148	0,9558	142,6362	0,3540	252,2293	557,9302	6,5255	9,2126	0,0010	2,8774	-0,3383	0,9851
82			0,0018	13,5382	0,9713	235,5805	0,3411	215,1941	928,7840	6,9654	9,7425	0,0010	2,9405	-0,3697	0,9928
83			0,0017	15,5037	0,9740	298,7072	0,3436	218,5937	1179,3252	7,1150	9,9342	0,0008	3,0019	-0,3779	0,9943
84			0,0011	15,5139	0,9887	686,2104	0,3668	283,6374	2729,3279	7,7307	10,4506	0,0008	2,9345	-0,4486	0,9986
85			0,0015	20,7718	0,9672	316,6755	0,3302	283,4919	1245,9301	7,1623	10,1113	0,0007	3,1326	-0,3624	0,9922
86			0,0031	11,7976	0,9354	91,2451	0,3491	268,5999	353,1827	6,2675	8,9406	0,0009	2,8411	-0,3105	0,9760
87			0,0011	33,9142	0,9541	369,1095	0,2586	292,3816	1442,5238	7,2605	10,5687	0,0005	3,4688	-0,3162	0,9871
88			0,0016	10,2694	0,9873	404,9690	0,3796	214,4672	1609,6067	7,3499	9,9115	0,0010	2,7526	-0,4407	0,9978
89			0,0011	30,3430	0,9554	340,2944	0,2689	244,6439	1330,8344	7,1607	10,4092	0,0007	3,4461	-0,3152	0,9866
90			0,0034	6,4328	0,9796	157,5973	0,4602	301,9436	623,9564	6,6581	8,8098	0,0012	2,4157	-0,4454	0,9960
91			0,0041	6,2699	0,9703	105,4460	0,4530	306,7014	415,5141	6,3716	8,5559	0,0011	2,4215	-0,4109	0,9921
92			0,0014	13,6731	0,9806	352,6752	0,3385	226,1584	1397,0277	7,2588	10,0539	0,0009	2,9610	-0,3956	0,9959
93			0,0025	8,9091	0,9800	222,9844	0,3912	299,6040	883,0285	6,8664	9,3043	0,0009	2,6559	-0,4160	0,9954
94			0,0012	17,3580	0,9851	584,3069	0,3545	308,2330	2319,8695	7,5956	10,3803	0,0007	3,0034	-0,4276	0,9979
95			0,0010	27,5485	0,9569	319,8124	0,2534	218,6848	1251,7013	7,1834	10,4943	0,0006	3,4252	-0,3073	0,9868
96			0,0018	15,3964	0,9717	271,8770	0,3547	223,7511	1072,1118	7,0530	9,8371	0,0009	2,9679	-0,3780	0,9937
97			0,0018	10,2613	0,9842	323,9680	0,3705	312,0388	1285,6107	7,1333	9,7295	0,0008	2,7838	-0,4160	0,9964
98			0,0036	7,3721	0,9714	129,0805	0,4245	307,2452	508,9501	6,4413	8,7406	0,0010	2,5308	-0,3973	0,9923
99			0,0016	16,1510	0,9715	283,5408	0,3417	276,5291	1118,0123	7,0788	9,9026	0,0008	2,9996	-0,3739	0,9930
100			0,0016	13,0115	0,9801	327,3626	0,3386	276,6048	1296,4388	7,0992	9,8585	0,0008	2,9188	-0,3864	0,9945
101			0,0047	5,6057	0,9741	108,2640	0,4778	318,4202	427,4503	6,3510	8,3907	0,0013	2,3286	-0,4348	0,9941
102			0,0029	16,3424	0,9553	182,7870	0,3946	296,3484	714,8056	6,7252	9,3010	0,0010	2,8547	-0,3786	0,9912
103			0,0008	25,4321	0,9782	583,0701	0,2687	216,9201	2306,8483	7,6000	10,8434	0,0006	3,3635	-0,3598	0,9950
104			0,0016	21,6547	0,9580	257,5378	0,3189	288,7748	1008,4964	7,0201	10,0271	0,0007	3,1838	-0,3386	0,9888
105		Waru	0,0018	13,1759	0,9754	267,4510	0,3406	241,9558	1056,6281	7,0560	9,8186	0,0009	2,9298	-0,3814	0,9940
106			0,0016	18,4007	0,9631	249,0393	0,3272	276,7345	977,7565	7,0051	9,9531	0,0007	3,1088	-0,3464	0,9906

No	Kelas Kuat / Label	Kayu	Nilai Fitur GLCM												
			ASM	Cont.	Corr.	Var.	IDM	Σ Avg.	Σ Var.	Σ Entr.	Entr.	Δ Var.	Δ Entr.	MoC I	MoC II
107	III	Waru	0,0035	8,8496	0,9575	104,0878	0,3934	249,2777	407,5014	6,3370	8,7959	0,0012	2,6701	-0,3568	0,9867
108			0,0016	19,9786	0,9744	391,3766	0,3179	300,1487	1545,5276	7,1831	10,1170	0,0007	3,1287	-0,3665	0,9935
109			0,0022	7,6571	0,9890	347,3681	0,4100	237,9229	1381,8154	7,0839	9,4746	0,0011	2,5938	-0,4446	0,9974
110			0,0008	23,1314	0,9840	722,5751	0,2729	203,3974	2867,1688	7,6578	10,8471	0,0006	3,3129	-0,3735	0,9959
111			0,0016	25,2557	0,9389	206,8577	0,2875	242,9241	802,1752	6,8633	10,0239	0,0007	3,2992	-0,2972	0,9787
112			0,0021	13,1619	0,9618	172,2819	0,3361	261,3369	675,9657	6,7405	9,5046	0,0009	2,9183	-0,3483	0,9882
113			0,0043	14,5436	0,9470	137,2853	0,4215	304,3572	534,5978	6,4155	8,8574	0,0011	2,7823	-0,3685	0,9873
114			0,0013	22,1616	0,9707	378,4936	0,3234	273,2514	1491,8129	7,2831	10,2857	0,0007	3,1718	-0,3658	0,9931
115			0,0043	11,5182	0,9473	109,2703	0,4157	312,7696	425,5630	6,2855	8,7002	0,0011	2,6722	-0,3592	0,9849
116			0,0020	20,7636	0,9395	171,5561	0,3130	251,6676	665,4607	6,7177	9,6816	0,0008	3,1781	-0,3126	0,9811
117			0,0012	36,5061	0,9439	325,0529	0,2488	300,7825	1263,7056	7,1359	10,5000	0,0005	3,5325	-0,2938	0,9825
118			0,0031	7,5190	0,9716	132,4564	0,4024	310,3869	522,3067	6,5493	8,9255	0,0010	2,5787	-0,3948	0,9926
119			0,0026	9,3312	0,9716	163,9874	0,3775	319,5602	646,6186	6,6758	9,2100	0,0009	2,7127	-0,3808	0,9919
120			0,0021	14,7832	0,9643	207,0229	0,3362	265,4323	813,3083	6,8608	9,6670	0,0008	2,9730	-0,3546	0,9895
121			0,0018	14,0596	0,9704	237,7882	0,3299	250,0604	937,0932	6,9121	9,7447	0,0008	2,9825	-0,3562	0,9913
122			0,0018	18,7465	0,9616	244,3062	0,3470	286,7328	958,4783	6,9922	9,8821	0,0007	3,0646	-0,3548	0,9909
123			0,0020	15,1855	0,9629	204,9576	0,3290	257,7352	804,6451	6,8430	9,6952	0,0007	3,0222	-0,3447	0,9893
124			0,0016	13,3858	0,9822	375,1056	0,3374	252,7085	1487,0367	7,2008	9,9606	0,0009	2,9494	-0,3958	0,9955
125			0,0026	8,7109	0,9731	162,1159	0,3818	247,8210	639,7525	6,7060	9,1962	0,0010	2,6722	-0,3911	0,9931
126			0,0018	9,7439	0,9891	446,3780	0,4137	315,1288	1775,7682	7,4113	9,8576	0,0009	2,6628	-0,4635	0,9985
127			0,0017	14,1237	0,9758	291,7345	0,3613	278,0001	1152,8144	7,0939	9,8161	0,0009	2,9082	-0,3917	0,9946
128			0,0021	14,8618	0,9591	181,5435	0,3349	261,7352	711,3121	6,7497	9,5426	0,0009	2,9662	-0,3448	0,9872
129			0,0020	21,4671	0,9543	235,0468	0,3247	304,9627	918,7200	6,8959	9,8522	0,0007	3,1602	-0,3333	0,9874
130			0,0011	18,1919	0,9864	670,1035	0,2982	219,9743	2662,2222	7,3749	10,3795	0,0007	3,1576	-0,3774	0,9952
131	IV	Sengon Laut	0,0017	17,8104	0,9616	231,9944	0,3299	279,6281	910,1670	6,9395	9,8255	0,0008	3,0681	-0,3496	0,9900
132			0,0050	5,7948	0,9674	88,7664	0,4536	298,6333	349,2709	6,1734	8,2944	0,0013	2,3863	-0,4007	0,9900
133			0,0044	5,6456	0,9698	93,3921	0,4485	316,1596	367,9228	6,2935	8,4606	0,0011	2,4048	-0,4053	0,9921
134			0,0020	9,6382	0,9834	290,1184	0,3919	251,0942	1150,8355	7,0799	9,5860	0,0010	2,7269	-0,4256	0,9967
135			0,0012	26,8439	0,9578	318,3393	0,2759	254,1044	1246,5134	7,1636	10,3704	0,0007	3,3633	-0,3216	0,9875
136			0,0007	27,2857	0,9853	925,8881	0,2558	204,7482	3676,2666	7,7978	11,1000	0,0005	3,4231	-0,3700	0,9961
137			0,0017	12,9227	0,9766	276,1151	0,3497	235,4832	1091,5379	7,0564	9,7922	0,0009	2,9030	-0,3861	0,9947
138			0,0015	15,1777	0,9735	285,9417	0,3334	221,7701	1128,5890	7,1039	9,9587	0,0008	3,0111	-0,3713	0,9938
139			0,0018	15,6233	0,9710	269,7581	0,3253	244,3360	1063,4092	7,0011	9,8570	0,0009	3,0098	-0,3618	0,9912
140			0,0017	12,0626	0,9789	285,6935	0,3473	245,6584	1130,7115	7,0781	9,7753	0,0010	2,8650	-0,3945	0,9947
141			0,0014	15,4375	0,9768	332,1047	0,3237	214,2570	1312,9815	7,2089	10,0978	0,0008	3,0462	-0,3764	0,9947
142			0,0020	15,5562	0,9577	183,9010	0,3252	246,2169	720,0477	6,7883	9,6439	0,0008	3,0162	-0,3385	0,9872

No	Kelas Kuat / Label	Kayu	Nilai Fitur GLCM												
			ASM	Cont.	Corr.	Var.	IDM	Σ Avg.	Σ Var.	Σ Entr.	Entr.	Δ Var.	Δ Entr.	MoC I	MoC II
143	IV	Sengon Laut	0,0014	21,2661	0,9747	420,6706	0,3071	278,9661	1661,4162	7,2648	10,2615	0,0007	3,1545	-0,3653	0,9933
144			0,0011	27,1096	0,9609	346,8555	0,2670	215,2995	1360,3122	7,1981	10,4624	0,0006	3,3890	-0,3173	0,9884
145			0,0031	7,3734	0,9757	151,7612	0,4046	302,8604	599,6712	6,6184	8,9730	0,0010	2,5694	-0,4056	0,9936
146			0,0017	17,7196	0,9575	208,3475	0,3119	251,2367	815,6705	6,8526	9,7991	0,0008	3,0893	-0,3308	0,9859
147			0,0017	14,7074	0,9694	240,3525	0,3410	226,0795	946,7025	6,9651	9,7905	0,0009	2,9966	-0,3623	0,9925
148			0,0025	8,3662	0,9808	217,6784	0,4286	209,0603	862,3473	6,8813	9,2619	0,0013	2,6043	-0,4278	0,9960
149			0,0020	12,0427	0,9720	215,0960	0,3482	259,4725	848,3413	6,8884	9,5672	0,0009	2,8580	-0,3785	0,9925
150			0,0022	12,7331	0,9663	188,8462	0,3504	259,0110	742,6518	6,7640	9,4696	0,0009	2,8789	-0,3610	0,9901
151			0,0013	21,1732	0,9804	540,3569	0,3305	305,0032	2140,2543	7,4842	10,4564	0,0006	3,1671	-0,3896	0,9963
152			0,0021	21,1747	0,9443	190,1537	0,3243	297,7619	739,4399	6,7479	9,6901	0,0007	3,1528	-0,3194	0,9826
153			0,0010	22,8451	0,9876	919,5302	0,2888	222,9708	3655,2756	7,4887	10,5917	0,0007	3,2758	-0,3731	0,9954
154			0,0020	14,3932	0,9743	280,3580	0,3624	316,0997	1107,0387	7,0465	9,7136	0,0008	2,8884	-0,3958	0,9949
155		Sengon Tekek	0,0025	11,2114	0,9701	187,6749	0,3837	219,1066	739,4881	6,7934	9,3862	0,0011	2,7986	-0,3831	0,9930
156			0,0030	8,0210	0,9776	179,4061	0,4257	317,6958	709,6035	6,6882	8,9995	0,0011	2,5674	-0,4205	0,9949
157			0,0012	27,4147	0,9513	281,6889	0,2671	223,9035	1099,3410	7,0848	10,3472	0,0007	3,3890	-0,3047	0,9857
158			0,0018	18,1313	0,9659	265,7668	0,3224	238,9094	1044,9357	6,9953	9,9359	0,0008	3,1042	-0,3468	0,9910
159			0,0031	8,6424	0,9785	200,8111	0,4011	313,1535	794,6019	6,6565	9,1097	0,0009	2,6551	-0,3938	0,9934
160			0,0025	14,0252	0,9542	153,2278	0,3362	257,5652	598,8860	6,5830	9,3925	0,0008	2,9710	-0,3233	0,9840
161			0,0009	25,7354	0,9718	456,1309	0,2676	207,7621	1798,7881	7,4016	10,6421	0,0006	3,3702	-0,3413	0,9926
162			0,0044	4,8163	0,9747	95,0217	0,4670	287,5801	375,2703	6,3089	8,3609	0,0013	2,2978	-0,4281	0,9934
163			0,0014	21,2118	0,9656	307,9329	0,3160	279,1175	1210,5199	7,1467	10,1684	0,0007	3,1796	-0,3491	0,9911
164			0,0028	10,3445	0,9629	139,3564	0,3719	264,7448	547,0812	6,5838	9,1490	0,0010	2,7420	-0,3657	0,9885
165			0,0015	17,3771	0,9771	380,1616	0,3466	281,7398	1503,2694	7,2470	10,0639	0,0008	3,0277	-0,3914	0,9952
166			0,0021	8,7910	0,9865	325,4181	0,4203	302,7848	1292,8815	7,1715	9,5533	0,0010	2,6053	-0,4535	0,9978
167			0,0052	5,1729	0,9624	68,7337	0,4389	319,0849	269,7621	6,0567	8,2121	0,0012	2,3702	-0,3811	0,9881
168			0,0045	9,0462	0,9595	111,6494	0,4319	307,8708	437,5516	6,2472	8,5521	0,0011	2,5694	-0,3748	0,9871
169			0,0008	27,0138	0,9815	728,3544	0,2626	227,4058	2886,4039	7,5979	10,8803	0,0005	3,4056	-0,3550	0,9946
170			0,0023	12,4899	0,9557	140,9554	0,3390	246,0156	551,3317	6,5920	9,3324	0,0010	2,9052	-0,3364	0,9862
171			0,0026	10,8902	0,9581	129,8280	0,3532	238,4480	508,4218	6,5325	9,1960	0,0010	2,8314	-0,3423	0,9867
172			0,0009	25,0499	0,9696	411,7657	0,2551	232,2000	1622,0128	7,3497	10,6262	0,0006	3,3845	-0,3302	0,9914
173			0,0012	19,5049	0,9758	403,0506	0,3173	277,3416	1592,6975	7,3445	10,3233	0,0007	3,1247	-0,3755	0,9944
174			0,0015	18,4148	0,9613	238,0249	0,3003	225,3974	933,6848	6,9449	9,9674	0,0008	3,1601	-0,3279	0,9885
175			0,0022	14,7238	0,9568	170,5323	0,3285	257,5993	667,4054	6,7134	9,5476	0,0008	2,9933	-0,3342	0,9861
176			0,0024	8,1473	0,9796	199,5595	0,4016	224,5946	790,0909	6,8499	9,2861	0,0011	2,6328	-0,4148	0,9955
177			0,0033	8,1088	0,9596	100,2466	0,3925	307,1781	392,8775	6,3435	8,7701	0,0010	2,6182	-0,3638	0,9871
178			0,0038	6,8182	0,9645	95,9514	0,4241	327,7879	376,9873	6,3171	8,6039	0,0010	2,4953	-0,3862	0,9895

Lampiran IV Nilai Fitur Setelah Di-scaling

No	Kelas Kuat / Label	Kayu	Nilai Fitur										
			Blue	Green	Red	Cont.	Corr.	Var.	IDM	Entr.	Δ Entr.	MoC I	MoC II
1	II	Akasia	0,4911	0,5715	0,5726	0,1597	0,6439	0,0469	0,5621	0,3914	0,3561	0,4535	0,7427
2			0,1994	0,2410	0,2702	0,6420	0,7075	0,2479	0,1570	0,9255	0,8121	0,5836	0,8221
3			0,3850	0,4077	0,3656	0,8900	0,3075	0,1386	0,0730	0,8745	0,9377	0,8522	0,4086
4			0,5562	0,7835	1,0000	0,5888	0,6193	0,1734	0,3286	0,7439	0,6888	0,5134	0,7977
5			0,2924	0,3465	0,3472	0,1966	0,9625	0,4156	0,4830	0,7957	0,4344	0,1132	0,9900
6			0,3898	0,4811	0,5066	0,2147	0,6536	0,0672	0,4215	0,5144	0,4704	0,5233	0,7551
7			0,6077	0,7678	0,9403	0,7950	0,5198	0,1851	0,1700	0,8392	0,8319	0,6551	0,6998
8			0,7105	0,8311	0,8683	0,3401	0,9194	0,4107	0,5267	0,8173	0,5312	0,1603	0,9870
9			0,4439	0,2815	0,0980	0,0636	0,9141	0,1190	0,7886	0,4472	0,1913	0,0813	0,9705
10			0,5660	0,6875	0,8250	0,2763	0,7470	0,1258	0,5681	0,6002	0,4583	0,3511	0,8870
11			0,7860	0,8525	0,8005	0,2815	0,7644	0,1381	0,6930	0,5166	0,4045	0,2128	0,9328
12			0,4412	0,4093	0,3358	0,3349	0,5109	0,0693	0,4447	0,5474	0,5529	0,5823	0,6763
13			0,4202	0,2716	0,1222	0,1567	0,8614	0,1408	0,5823	0,5719	0,3687	0,2513	0,9423
14			0,8612	0,8163	0,6452	0,0227	0,8004	0,0261	0,8918	0,1749	0,0792	0,1973	0,8825
15			0,3405	0,4973	0,5922	0,6658	0,5133	0,1507	0,1996	0,8163	0,8064	0,6642	0,6736
16			0,4146	0,4884	0,4763	0,2214	0,7352	0,0967	0,4851	0,5480	0,4464	0,4213	0,8258
17			0,7957	0,8077	0,6974	0,0577	0,8033	0,0457	0,7817	0,2923	0,1732	0,2346	0,8954
18			0,4612	0,5910	0,7275	0,3702	0,8645	0,2971	0,4280	0,8346	0,5842	0,3005	0,9522
19			0,2923	0,3697	0,3722	0,3542	0,5514	0,0829	0,3142	0,6143	0,6089	0,6243	0,6748
20			0,3616	0,4547	0,4969	0,2789	0,9651	0,5633	0,3560	0,8241	0,5508	0,2672	0,9638
21		Jati	0,4459	0,4703	0,4181	0,2970	0,7232	0,1224	0,4211	0,6237	0,5250	0,4654	0,8150
22			0,4707	0,5254	0,4620	0,2774	0,6544	0,0883	0,3939	0,5853	0,5241	0,5229	0,7612
23			0,5120	0,6190	0,5974	0,1350	0,7618	0,0694	0,5750	0,4342	0,3356	0,3547	0,8540
24			0,5735	0,6015	0,5245	0,2123	0,7109	0,0837	0,4810	0,5299	0,4345	0,4256	0,8177
25			0,5527	0,6580	0,6518	0,1236	0,7029	0,0472	0,6417	0,3598	0,2951	0,3770	0,8121
26			0,7480	0,7449	0,6460	0,1564	0,8063	0,1004	0,8331	0,4281	0,2675	0,1505	0,9463
27			0,3745	0,4119	0,3786	0,1270	0,7871	0,0755	0,6219	0,4431	0,3131	0,3083	0,8772
28			0,7173	0,8001	0,7405	0,0360	0,8036	0,0341	0,9460	0,1882	0,0783	0,1332	0,9117
29			0,3529	0,4109	0,4095	0,2364	0,8439	0,1770	0,4346	0,6633	0,4825	0,3399	0,9103
30			0,8837	0,8641	0,7134	0,0000	0,7003	0,0000	1,0000	0,0000	0,0000	0,2470	0,8101
31			0,3045	0,4045	0,4742	0,1841	0,8814	0,1837	0,4636	0,6393	0,4268	0,2829	0,9389
32			0,4822	0,5834	0,7276	0,3855	0,7555	0,1794	0,3930	0,7124	0,5919	0,4460	0,8543
33			0,8495	0,9215	0,8735	0,0663	0,6782	0,0214	0,7860	0,2001	0,1815	0,3380	0,7900
34			0,2622	0,4091	0,5131	0,4469	0,8002	0,2510	0,3070	0,8337	0,6705	0,4372	0,8928

No	Kelas Kuat / Label	Kayu	Nilai Fitur										
			Blue	Green	Red	Cont.	Corr.	Var.	IDM	Entr.	Δ Entr.	MoC I	MoC II
35	II	Jati	0,6096	0,7245	0,8385	0,2127	0,7739	0,1112	0,5663	0,5461	0,4087	0,3272	0,8896
36			0,6687	0,8396	0,9291	0,3027	0,7590	0,1459	0,6665	0,4742	0,3796	0,2595	0,9104
37			0,4956	0,6781	0,8540	0,6800	0,7270	0,2820	0,2990	0,8413	0,7348	0,4868	0,8665
38			0,0000	0,0000	0,0000	0,2725	1,0000	1,0000	0,4203	0,8923	0,5257	0,1323	0,9947
39			0,8926	0,9532	0,8517	0,0478	0,8108	0,0427	0,9214	0,2083	0,1068	0,1357	0,9120
40			0,5279	0,6463	0,7697	0,2590	0,7612	0,1259	0,4994	0,5983	0,4746	0,3733	0,8720
41			0,5358	0,4349	0,2988	0,0456	0,8362	0,0507	0,8182	0,2797	0,1566	0,1813	0,9208
42			0,2909	0,4276	0,5570	0,5185	0,6683	0,1759	0,2172	0,7954	0,7289	0,5865	0,7887
43			0,4094	0,4437	0,3927	0,2071	0,7423	0,0936	0,5406	0,5338	0,4168	0,3820	0,8491
44			0,8221	0,8107	0,6828	0,1258	0,8645	0,1216	0,8144	0,4449	0,2515	0,1195	0,9591
45			0,5269	0,3516	0,1627	0,2095	0,7173	0,0848	0,5181	0,5308	0,4402	0,4247	0,8405
46			0,1754	0,2371	0,3068	0,7121	0,6367	0,2213	0,1427	0,9217	0,8455	0,6397	0,7744
47			0,2464	0,4231	0,5674	0,2422	0,8281	0,1652	0,3822	0,6855	0,5087	0,3735	0,9082
48			0,5062	0,4796	0,3881	0,2370	0,6135	0,0645	0,4787	0,5014	0,4587	0,5035	0,7326
49		Mahoni	0,3383	0,3425	0,3213	0,1362	0,8380	0,1083	0,6481	0,5005	0,3311	0,2465	0,9305
50			0,4226	0,4412	0,4329	0,3132	0,5418	0,0701	0,4266	0,5337	0,5471	0,5871	0,6899
51			0,4806	0,6548	0,8608	0,4060	0,8896	0,3804	0,3621	0,8839	0,6223	0,2648	0,9670
52			0,4957	0,6043	0,7316	0,1929	0,8100	0,1226	0,6298	0,5478	0,3715	0,2648	0,9205
53			0,3383	0,4195	0,4607	0,4514	0,6705	0,1539	0,2343	0,7750	0,6917	0,5699	0,7952
54			0,1692	0,2393	0,3142	0,5591	0,3912	0,0949	0,1671	0,7280	0,7733	0,7767	0,4982
55			0,5704	0,6150	0,5723	0,1432	0,6530	0,0433	0,5396	0,3812	0,3504	0,4676	0,7487
56			0,4823	0,6484	0,8393	0,2353	0,7393	0,1044	0,5627	0,5498	0,4300	0,3549	0,8754
57			0,3247	0,4332	0,5514	1,0000	0,0000	0,1014	0,0000	0,8494	1,0000	1,0000	0,0000
58			0,5797	0,7382	0,9002	0,3819	0,6815	0,1347	0,3937	0,6869	0,5956	0,4955	0,8170
59			0,4217	0,3204	0,1959	0,1637	0,8512	0,1363	0,5463	0,5822	0,3890	0,2749	0,9345
60			0,4617	0,5728	0,7077	0,3646	0,8187	0,2270	0,4510	0,7202	0,5652	0,3655	0,9006
61			0,6309	0,5856	0,4621	0,2382	0,6776	0,0822	0,4926	0,5405	0,4695	0,4685	0,7961
62			0,5255	0,5072	0,4060	0,3478	0,7005	0,1312	0,3964	0,6706	0,5661	0,4694	0,8179
63			0,4563	0,5710	0,7071	0,3162	0,7599	0,1512	0,4877	0,6577	0,5199	0,3710	0,8828
64			0,5591	0,6897	0,8098	0,4102	0,8643	0,3257	0,3805	0,8605	0,6129	0,2926	0,9601
65			0,6181	0,7240	0,8080	0,2889	0,7536	0,1350	0,5307	0,6142	0,4877	0,3593	0,8846
66			0,5648	0,6570	0,7512	0,2773	0,7282	0,1167	0,5122	0,5897	0,4810	0,3859	0,8639
67			0,3881	0,4229	0,3839	0,2103	0,8699	0,1890	0,4729	0,6662	0,4540	0,2632	0,9448
68			0,7099	0,8505	0,9157	0,1630	0,8157	0,1095	0,7149	0,4557	0,3068	0,2108	0,9319
69			0,4494	0,3130	0,1543	0,1753	0,9086	0,2188	0,6118	0,6616	0,3935	0,1699	0,9699
70			0,4557	0,4740	0,4667	0,1422	0,9002	0,1745	0,5266	0,5992	0,3739	0,2300	0,9515

No	Kelas Kuat / Label	Kayu	Nilai Fitur										
			Blue	Green	Red	Cont.	Corr.	Var.	IDM	Entr.	Δ Entr.	MoC I	MoC II
71	II	Mahoni	0,5984	0,5783	0,4750	0,1506	0,7701	0,0799	0,5827	0,4742	0,3617	0,3532	0,8730
72			0,4947	0,6483	0,7967	0,3332	0,7925	0,1838	0,4968	0,6932	0,5247	0,3393	0,9051
73			0,5424	0,4812	0,3725	0,1776	0,8361	0,1326	0,5106	0,5778	0,4106	0,3218	0,9099
74			0,4315	0,5815	0,7805	0,4099	0,7127	0,1615	0,3439	0,7284	0,6101	0,4625	0,8505
75			0,4550	0,2738	0,0838	0,1353	0,9436	0,2545	0,6344	0,6525	0,3308	0,0859	0,9872
76			0,0556	0,0957	0,1655	0,3480	0,9692	0,7125	0,3462	0,9033	0,6064	0,2320	0,9785
77	III	Trembesi	0,7985	0,7722	0,6696	0,0866	0,7930	0,0573	0,6709	0,3542	0,2442	0,2964	0,8713
78			0,4414	0,2882	0,1187	0,1400	0,8683	0,1354	0,5897	0,5526	0,3498	0,2415	0,9441
79			0,5129	0,6684	0,8324	0,3462	0,7456	0,1554	0,4441	0,6916	0,5612	0,4249	0,8657
80			0,6114	0,7325	0,8576	0,2316	0,6914	0,0842	0,5513	0,5092	0,4353	0,4175	0,8292
81			0,3856	0,4736	0,5192	0,1769	0,6733	0,0593	0,5511	0,4213	0,3903	0,4575	0,7725
82			0,4589	0,2748	0,0796	0,1966	0,8037	0,1205	0,5069	0,5838	0,4284	0,3425	0,9012
83			0,4513	0,2913	0,1235	0,2384	0,8272	0,1620	0,5153	0,6425	0,4655	0,3126	0,9272
84			0,5006	0,6466	0,8115	0,2386	0,9506	0,4170	0,5948	0,8009	0,4248	0,0546	1,0000
85			0,5891	0,6675	0,7322	0,3505	0,7695	0,1739	0,4696	0,6968	0,5445	0,3693	0,8916
86			0,4690	0,5729	0,6450	0,1595	0,5012	0,0255	0,5344	0,3379	0,3683	0,5590	0,6172
87			0,5639	0,7002	0,8697	0,6302	0,6589	0,2084	0,2246	0,8371	0,7477	0,5379	0,8058
88			0,3766	0,2584	0,1282	0,1270	0,9390	0,2320	0,6387	0,6356	0,3149	0,0834	0,9870
89			0,3034	0,4311	0,4725	0,5542	0,6701	0,1894	0,2598	0,7882	0,7339	0,5419	0,7977
90			0,8463	0,8352	0,6966	0,0453	0,8739	0,0692	0,9143	0,2977	0,1112	0,0663	0,9559
91			0,7904	0,8548	0,7841	0,0419	0,7954	0,0349	0,8895	0,2199	0,1148	0,1921	0,8894
92			0,3866	0,3227	0,2503	0,1994	0,8825	0,1975	0,4980	0,6792	0,4408	0,2481	0,9540
93			0,8695	0,8203	0,6678	0,0980	0,8775	0,1122	0,6784	0,4494	0,2564	0,1736	0,9451
94			0,6648	0,8298	0,9174	0,2779	0,9207	0,3500	0,5527	0,7793	0,4664	0,1313	0,9883
95			0,1671	0,2484	0,3253	0,4947	0,6830	0,1759	0,2069	0,8143	0,7213	0,5705	0,8009
96			0,5032	0,3273	0,1415	0,2361	0,8073	0,1444	0,5534	0,6128	0,4450	0,3125	0,9175
97			0,9629	0,9062	0,7304	0,1268	0,9124	0,1787	0,6075	0,5798	0,3337	0,1738	0,9622
98			0,8679	0,8678	0,7389	0,0653	0,8052	0,0504	0,7921	0,2765	0,1808	0,2418	0,8927
99			0,4770	0,5979	0,7626	0,2522	0,8059	0,1521	0,5091	0,6328	0,4641	0,3273	0,9061
100			0,5929	0,6580	0,6013	0,1853	0,8784	0,1809	0,4984	0,6193	0,4153	0,2816	0,9306
101			0,8492	0,9316	0,8639	0,0277	0,8277	0,0367	0,9745	0,1693	0,0586	0,1051	0,9240
102			0,8068	0,7908	0,6798	0,2562	0,6692	0,0858	0,6900	0,4484	0,3765	0,3103	0,8745
103			0,1563	0,2325	0,3222	0,4497	0,8621	0,3492	0,2591	0,9213	0,6840	0,3789	0,9386
104			0,5248	0,6743	0,8582	0,3693	0,6917	0,1349	0,4309	0,6710	0,5754	0,4564	0,8341
105		Waru	0,6007	0,4471	0,2617	0,1888	0,8382	0,1415	0,5050	0,6071	0,4219	0,2999	0,9224
106			0,4692	0,6083	0,7496	0,3000	0,7346	0,1294	0,4593	0,6483	0,5301	0,4277	0,8641

No	Kelas Kuat / Label	Kayu	Nilai Fitur										
			Blue	Green	Red	Cont.	Corr.	Var.	IDM	Entr.	Δ Entr.	MoC I	MoC II
107	III	Waru	0,3794	0,4559	0,4933	0,0968	0,6877	0,0340	0,6858	0,2935	0,2650	0,3897	0,7993
108			0,6134	0,7608	0,8981	0,3336	0,8306	0,2230	0,4276	0,6986	0,5421	0,3543	0,9143
109			0,4417	0,4008	0,3290	0,0714	0,9530	0,1941	0,7427	0,5016	0,2189	0,0693	0,9795
110			0,1625	0,1615	0,1677	0,4007	0,9110	0,4410	0,2735	0,9224	0,6534	0,3287	0,9550
111			0,4058	0,4299	0,3959	0,4459	0,5315	0,1016	0,3237	0,6700	0,6452	0,6075	0,6640
112			0,4090	0,5378	0,5822	0,1885	0,7240	0,0788	0,4897	0,5108	0,4149	0,4208	0,8244
113			0,7733	0,8439	0,7619	0,2180	0,5996	0,0558	0,7819	0,3124	0,3328	0,3471	0,8084
114			0,5325	0,6004	0,6647	0,3801	0,7992	0,2145	0,4462	0,7503	0,5682	0,3571	0,9067
115			0,8913	0,8978	0,7896	0,1536	0,6017	0,0374	0,7621	0,2641	0,2662	0,3810	0,7686
116			0,2973	0,4532	0,5830	0,3503	0,5361	0,0784	0,4108	0,5651	0,5720	0,5512	0,7048
117			0,6145	0,7594	0,9141	0,6854	0,5728	0,1794	0,1911	0,8160	0,7861	0,6199	0,7280
118			0,8449	0,8850	0,7821	0,0684	0,8067	0,0526	0,7167	0,3332	0,2097	0,2511	0,8979
119			0,9456	0,9472	0,8180	0,1070	0,8062	0,0734	0,6312	0,4205	0,2908	0,3023	0,8860
120			0,5641	0,5941	0,4957	0,2231	0,7450	0,1017	0,4902	0,5606	0,4480	0,3979	0,8460
121			0,6647	0,5001	0,3085	0,2077	0,7968	0,1219	0,4687	0,5844	0,4538	0,3918	0,8761
122			0,5842	0,6840	0,7716	0,3074	0,7226	0,1262	0,5269	0,6266	0,5034	0,3971	0,8692
123			0,6415	0,5501	0,3849	0,2316	0,7337	0,1003	0,4654	0,5693	0,4778	0,4340	0,8424
124			0,5010	0,4999	0,4307	0,1933	0,8955	0,2123	0,4943	0,6506	0,4338	0,2472	0,9480
125			0,6245	0,4854	0,3041	0,0938	0,8194	0,0722	0,6461	0,4162	0,2662	0,2646	0,9069
126			0,6856	0,8642	0,9904	0,1158	0,9539	0,2592	0,7551	0,6190	0,2606	0,0000	0,9977
127			0,5265	0,6278	0,7164	0,2090	0,8419	0,1574	0,5760	0,6063	0,4089	0,2622	0,9328
128			0,5024	0,5553	0,5176	0,2247	0,7010	0,0849	0,4855	0,5225	0,4439	0,4337	0,8068
129			0,6641	0,7952	0,9141	0,3653	0,6611	0,1201	0,4508	0,6174	0,5612	0,4756	0,8101
130			0,2367	0,2662	0,2904	0,2956	0,9315	0,4064	0,3602	0,7791	0,5596	0,3144	0,9430
131	IV	Sengon Laut	0,5574	0,6328	0,7287	0,2875	0,7225	0,1181	0,4686	0,6092	0,5055	0,4162	0,8549
132			0,7944	0,8063	0,7030	0,0318	0,7709	0,0239	0,8917	0,1397	0,0935	0,2295	0,8552
133			1,0000	0,9330	0,7520	0,0286	0,7912	0,0269	0,8741	0,1907	0,1047	0,2127	0,8899
134			0,5955	0,5013	0,3557	0,1136	0,9059	0,1564	0,6806	0,5358	0,2993	0,1384	0,9675
135			0,3479	0,4872	0,5492	0,4797	0,6906	0,1750	0,2839	0,7763	0,6839	0,5184	0,8127
136			0,1529	0,1726	0,1794	0,4891	0,9217	0,5747	0,2151	1,0000	0,7200	0,3417	0,9583
137			0,5101	0,3919	0,2666	0,1835	0,8487	0,1472	0,5363	0,5990	0,4057	0,2828	0,9341
138			0,4465	0,3108	0,1551	0,2314	0,8222	0,1536	0,4804	0,6500	0,4711	0,3368	0,9196
139			0,4497	0,4454	0,3770	0,2409	0,8019	0,1430	0,4527	0,6188	0,4703	0,3717	0,8741
140			0,4907	0,4586	0,3632	0,1652	0,8680	0,1535	0,5279	0,5938	0,3828	0,2523	0,9337
141			0,4340	0,2640	0,0905	0,2370	0,8500	0,1840	0,4473	0,6927	0,4923	0,3183	0,9340
142			0,3788	0,4432	0,4527	0,2395	0,6895	0,0865	0,4526	0,5535	0,4741	0,4565	0,8065

No	Kelas Kuat / Label	Kayu	Nilai Fitur										
			Blue	Green	Red	Cont.	Corr.	Var.	IDM	Entr.	Δ Entr.	MoC I	MoC II
143	IV	Sengon Laut	0,4516	0,6145	0,7916	0,3610	0,8325	0,2423	0,3907	0,7429	0,5577	0,3586	0,9099
144			0,1204	0,2059	0,3531	0,4854	0,7163	0,1937	0,2533	0,8045	0,6994	0,5339	0,8281
145			0,9219	0,8503	0,6573	0,0654	0,8412	0,0653	0,7241	0,3478	0,2041	0,2116	0,9155
146			0,4657	0,4887	0,4355	0,2855	0,6875	0,1026	0,4068	0,6011	0,5183	0,4846	0,7859
147			0,4678	0,3354	0,1914	0,2214	0,7881	0,1236	0,5066	0,5985	0,4623	0,3697	0,8976
148			0,4188	0,2317	0,0474	0,0865	0,8839	0,1087	0,8062	0,4364	0,2252	0,1305	0,9560
149			0,5055	0,5430	0,4911	0,1647	0,8100	0,1070	0,5310	0,5300	0,3785	0,3104	0,8975
150			0,4306	0,5360	0,5269	0,1794	0,7618	0,0897	0,5386	0,5001	0,3911	0,3745	0,8560
151			0,7168	0,8248	0,8363	0,3591	0,8808	0,3211	0,4707	0,8026	0,5653	0,2701	0,9618
152			0,6188	0,7508	0,8645	0,3591	0,5768	0,0906	0,4493	0,5677	0,5567	0,5264	0,7299
153			0,1573	0,2591	0,3996	0,3946	0,9412	0,5706	0,3280	0,8441	0,6310	0,3302	0,9459
154			0,7969	0,9011	0,8949	0,2148	0,8296	0,1500	0,5797	0,5749	0,3969	0,2474	0,9367
155		Sengon Tekek	0,4883	0,3007	0,1014	0,1470	0,7942	0,0890	0,6526	0,4745	0,3426	0,2939	0,9051
156			0,9465	0,9412	0,7903	0,0791	0,8575	0,0835	0,7961	0,3559	0,2029	0,1572	0,9377
157			0,2322	0,2931	0,3245	0,4919	0,6359	0,1508	0,2539	0,7692	0,6994	0,5800	0,7825
158			0,5484	0,4199	0,2706	0,2943	0,7585	0,1404	0,4428	0,6431	0,5273	0,4263	0,8722
159			0,9009	0,9040	0,7813	0,0924	0,8646	0,0976	0,7122	0,3897	0,2559	0,2546	0,9116
160			0,4338	0,5002	0,5628	0,2069	0,6602	0,0663	0,4903	0,4764	0,4468	0,5120	0,7533
161			0,1580	0,1837	0,2207	0,4561	0,8081	0,2656	0,2556	0,8596	0,6881	0,4462	0,8991
162			0,7127	0,7332	0,6400	0,0109	0,8323	0,0280	0,9375	0,1601	0,0400	0,1294	0,9114
163			0,5433	0,6274	0,7341	0,3599	0,7557	0,1681	0,4210	0,7143	0,5729	0,4180	0,8735
164			0,5490	0,5791	0,5162	0,1286	0,7331	0,0572	0,6122	0,4018	0,3085	0,3573	0,8296
165			0,5630	0,6495	0,7389	0,2783	0,8533	0,2156	0,5257	0,6823	0,4811	0,2633	0,9421
166			0,6842	0,8061	0,8387	0,0955	0,9320	0,1796	0,7779	0,5257	0,2258	0,0365	0,9869
167			0,8610	0,9354	0,8658	0,0185	0,7288	0,0107	0,8414	0,1145	0,0838	0,3011	0,8217
168			0,8214	0,8639	0,7785	0,1010	0,7046	0,0389	0,8173	0,2187	0,2041	0,3239	0,8057
169			0,2088	0,2952	0,4045	0,4834	0,8896	0,4448	0,2382	0,9326	0,7094	0,3965	0,9320
170			0,5352	0,4650	0,3403	0,1742	0,6725	0,0582	0,4996	0,4580	0,4070	0,4641	0,7896
171			0,4322	0,4042	0,3379	0,1402	0,6925	0,0509	0,5482	0,4162	0,3625	0,4426	0,7995
172			0,2068	0,3265	0,4464	0,4416	0,7896	0,2364	0,2128	0,8547	0,6967	0,4870	0,8777
173			0,4826	0,6039	0,7664	0,3235	0,8419	0,2307	0,4253	0,7618	0,5397	0,3216	0,9282
174			0,5193	0,3408	0,1460	0,3003	0,7199	0,1221	0,3672	0,6527	0,5611	0,4955	0,8286
175			0,4954	0,5286	0,4830	0,2218	0,6822	0,0777	0,4637	0,5240	0,4603	0,4723	0,7884
176			0,4113	0,3207	0,2097	0,0818	0,8738	0,0968	0,7138	0,4438	0,2424	0,1779	0,9472
177			0,9043	0,8665	0,7253	0,0810	0,7051	0,0314	0,6827	0,2856	0,2336	0,3641	0,8057
178			0,9605	1,0000	0,8853	0,0535	0,7465	0,0286	0,7907	0,2346	0,1593	0,2824	0,8457

BIODATA PENULIS

Nama : **Okta Dhirga Sukrisdyanto**
Jenis Kelamin : Pria
TTL : Trenggalek, 03 Oktober 1989
Alamat : RT 19 RW 04 Desa Karangsoko
Kec./Kab. Trenggalek
Email : okta.dhirga@gmail.com
Agama : Islam



Penulis merupakan anak kedua dari pasangan Bapak Sukri dan Ibu Mudiyah. *Alhamdulillah*, saat ini telah dianugerahi satu orang istri dan satu orang putri. Bekerja sebagai ASN di Pemerintah Kabupaten Trenggalek sejak Tahun 2009, tidak menyurutkan semangat penulis untuk terus belajar baik pendidikan formal maupun informal. Adapun untuk pendidikan formal yang telah penulis tempuh adalah sebagai berikut:

1. SDN 1 Karangsoko Trenggalek Lulus dan Berijazah Tahun 2002
2. MTsN Model Trenggalek Lulus dan Berijazah Tahun 2005
3. SMK Telkom Sandhy Putra Malang Lulus dan Berijazah Tahun 2008
4. Program D- IV Sekolah Tinggi Multi Media “MMTC” Yogyakarta Lulus dan Berijazah Tahun 2015
5. Program Magister Institut Teknologi Sepuluh Nopember (ITS) Surabaya Masuk Tahun 2017