



TESIS – KI092361

**IDENTIFIKASI PENYAKIT PADA DAUN TEBU
DENGAN *GRAY LEVEL CO-OCCURRENCE MATRIX*
DAN *COLOR MOMENTS***

Ratih Kartika Dewi
5112201051

DOSEN PEMBIMBING
Dr. Ir. R.V. Hari Ginardi, M.Sc.

PROGRAM MAGISTER
BIDANG KEAHLIAN KOMPUTASI CERDAS & VISUALISASI
JURUSAN TEKNIK INFORMATIKA
FAKULTAS TEKNOLOGI INFORMASI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2014



THESIS – KI092361

IDENTIFICATION OF SUGARCANE LEAF DISEASES BASED ON GRAY LEVEL CO-OCCURRENCE MATRIX AND COLOR MOMENTS

Ratih Kartika Dewi
5112201051

SUPERVISOR
Dr. Ir. R.V. Hari Ginardi, M.Sc.

MASTER PROGRAM
INTELLIGENT COMPUTING AND VISUALIZATION
DEPARTMENT OF INFORMATICS
FACULTY OF INFORMATION TECHNOLOGY
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2014

IDENTIFIKASI PENYAKIT PADA DAUN TEBU DENGAN *GRAY LEVEL CO-OCCURRENCE MATRIX* DAN *COLOR MOMENTS*

Nama mahasiswa : Ratih Kartika Dewi
NRP : 5112201051
Pembimbing I : Dr. Ir. R.V. Hari Ginardi, M.Sc.

ABSTRAK

Karat dan mosaik adalah penyakit pada tebu yang menyerang tebu di Indonesia dan menimbulkan kerugian. Teknologi informasi untuk deteksi penyakit tebu diperlukan dalam menunjang peningkatan produksi tebu yang dapat menghasilkan panen optimal. Penelitian yang berkembang mengenai identifikasi penyakit tanaman melalui identifikasi citra digital daun belum ada yang khusus membahas tebu, tetapi mengenai penyakit tanaman secara umum. Penelitian ini membangun sistem identifikasi penyakit tebu melalui identifikasi citra digital daun dengan pemilihan fitur tekstur dan warna melalui *gray level co-occurrence matrix* (GLCM) dan *color moments*.

Tahap awal penelitian adalah pengumpulan data citra daun tebu berpenyakit dari survei lapangan. Tahap selanjutnya adalah *pre-processing* citra untuk dapat diolah ke tahap selanjutnya yaitu ekstraksi fitur. Ekstraksi fitur tekstur dilakukan dengan *gray level co-occurrence matrix* (GLCM) dan ekstraksi fitur warna dengan *color moments*. Klasifikasi daun tebu berpenyakit dilakukan berdasarkan fitur yang telah diekstraksi sebelumnya. Penelitian ini menggunakan metode klasifikasi *support vector machine* (SVM). Strategi pengujian dilakukan untuk mengetahui fitur yang kemunculannya menyebabkan perubahan dalam hasil klasifikasi, yaitu dengan menguji sebuah fitur, per kelompok fitur, seluruh fitur kecuali 1 fitur kemudian seluruh fitur. Kombinasi fitur tekstur dengan GLCM *correlation*, *energy*, *homogeneity* dan *variance* bersama fitur warna dengan *color moment* 1,2 dan 3 merupakan kombinasi fitur yang direkomendasikan untuk identifikasi penyakit pada daun tebu.

Kata kunci: Ekstraksi fitur, penyakit tebu, citra daun, GLCM, dan *color moments*.

IDENTIFICATION OF SUGARCANE LEAF DISEASE BASED ON GRAY LEVEL CO-OCCURRENCE MATRIX AND COLOR MOMENTS

Name : Ratih Kartika Dewi
Student Identity Number : 5112201051
Supervisor : Dr. Ir. R.V. Hari Ginardi, M.Sc.

ABSTRACT

Mosaic and rust are sugarcane diseases that happen in Indonesia and has considerable economic impact. Information technology for sugarcane disease detection is useful in supporting optimal sugarcane production. Most of current researches are about plant disease identification in general. There is no specific research about identification of sugarcane disease. This research proposes a sugarcane disease identification from sugarcane leaf image with selection of gray level co-occurrence matrix (GLCM) and color moments.

This research begins with collecting data from field survey. After those sugarcane leaf images are captured through a field survey, they are pre-processed in order to be used in the features extraction step. Extracted features from these images are texture and color. Texture feature extraction is conducted by GLCM while color feature extraction is conducted by color moments. Classification method which is used in this research is support vector machine (SVM). To test distinctive feature that has a significant impact in classification, we test individual feature, group of feature, all of features except one and all of features. Texture feature with GLCM correlation, energy, homogeneity and variance combined with color moments 1, 2 and 3 for color feature extraction is an appropriate feature for identification of sugarcane leaf disease.

Keywords: feature extraction, sugarcane disease, leaf image, GLCM and color moments.

Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Komputer (M.Kom)

di
**Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember**


Oleh:
**RATIH KARTIKA DEWI
NRP: 5112201051**

Dengan judul:
**Identifikasi Penyakit pada Daun Tebu dengan *Gray Level Co-occurrence
Matrix* dan *Color Moments***


Tanggal Ujian: 3- 7- 2014
Periode Wisuda: 2013 Genap

Disetujui oleh:


Dr. Ir. R.V. Hari Ginardi, M.Sc.
NIP. 196505181992031003


.....
(Pembimbing)


Dr. Eng Nanik Suciati, S.Kom., M.Kom.
NIP. 197208091995121001


.....
(Penguji 1)

Diana Purwitasari, S.Kom., M.Sc
NIP. 197804102003122001


.....
(Penguji 2)

Wijayanti Nurul Khotimah, S.Kom, M.Sc.
NIP. 198603122012122004


.....
(Penguji 3)

Direktur Program Pascasarjana,


Prof. Dr. Ir. Adi Soeprijanto, M.T.

NIP. 196404051990021001



KATA PENGANTAR

Penulis bersyukur atas rahmat dan pertolongan-Nya sehingga penulis dapat menyelesaikan penelitian ini. Pada kesempatan ini penulis ingin mengucapkan banyak terima kasih kepada:

1. Orang tua penulis, Kolonel CKM dr. Teguh Ristiwanto, MARS dan dr. Happy Indah Hapsari, SpKJ beserta adik-adik dan segenap keluarga besar yang telah memberikan doa, motivasi, serta dukungan selama penulis menyelesaikan studi S2.
2. Bapak Dr. Ir. R V Hari Ginardi, M.Sc selaku dosen pembimbing tesis yang telah memberikan ilmu, meluangkan waktu, memberikan saran dan kritik yang membangun.
3. Bapak Prof. Drs.Ec. Ir. Rianarto Sarno, M.Sc., Ph.D selaku ketua tim penelitian tebu.
4. Tim Penguji Tesis, Ibu Dr. Eng Nanik Suciati, S.Kom., M.Kom., Ibu Diana Purwitasari, S.Kom., M.Sc, Ibu Wijayanti Nurul Khotimah, S.Kom, M.Sc. atas saran dan kritik yang membangun untuk penelitian ini.
5. Bapak Waskitho Wibisono, S.Kom, M.Eng, Ph.D selaku Ketua Program Studi Pascasarjana Informatika ITS sekaligus dosen wali penulis, yang telah memberikan saran yang membangun selama penulis menempuh studi S2.
6. Seluruh dosen Teknik Informatika ITS yang telah memberikan ilmunya selama penulis menempuh studi S2.
7. Seluruh karyawan Teknik Informatika ITS atas bantuan informasi, administrasi, laboratorium dan bantuan lainnya selama studi S2.
8. Pakar pertanian dari BALITTAS atas ilmu yang telah diberikan.
9. Teman-teman Tim Urinalysis dan Tim Tebu (Mbak Mentari, Mbak Ratna, Mbak Mutrofin, Yuita, Evy, Izzah, Rizka, Pak Ali dan Pak Taufik) atas kerjasama dalam menjalankan penelitian di Laboratorium Sistem Bisnis Cerdas, Teknik Informatika ITS.

10. Dosen Lab Mobile Universitas Brawijaya (Bapak Dr. Eng Herman Tolle, ST, MT, Bapak Aryo Pinandito, ST, MMT serta Bapak Agi Putra Kharisma, ST, MT) atas ilmu, motivasi dan dukungan selama penulis menyelesaikan studi S2.
11. Bapak Muhamad Arief Hidayat, S.Kom, M.Kom, Bapak Novanto Yudistira, S.Kom, M.Sc, Bapak Moch. Ali Fauzi, S.Kom, M.Kom, Bapak Putra Prima A, ST, M.Kom dan Bapak Randy Cahya Wihandika, S.ST, M.Kom atas kesediaan memberikan ilmu dan saran yang menunjang terselesaikannya penelitian ini.
12. Seluruh dosen dan karyawan PTIIK Universitas Brawijaya atas dukungannya selama menyelesaikan studi S2.
13. Para guru yang telah mendidik penulis mulai dari tingkat pendidikan dasar hingga sekarang.
14. Teman-teman Pascasarjana Informatika ITS angkatan 2012 dan 2011. Terima kasih atas bantuannya selama menjadi mahasiswa.
15. Teman-teman lain yang tidak dapat disebutkan satu persatu. Terima kasih atas dukungannya selama menyelesaikan studi.

Dengan segala keterbatasan, penulis menyadari bahwa penelitian ini masih jauh dari sempurna dan membutuhkan pengembangan lebih lanjut. Untuk itu penulis mengharapkan saran positif dari para pembaca.

Akhir kata, penulis berharap semoga penelitian ini dapat bermanfaat bagi banyak pihak terutama untuk pengembangan ilmu pengetahuan dan teknologi di bidang Komputasi Cerdas dan Visualisasi.

Surabaya, Juli 2014

Penulis

DAFTAR ISI

ABSTRAK	i
ABSTRACT	iii
KATA PENGANTAR	v
DAFTAR ISI.....	vii
DAFTAR GAMBAR	xi
DAFTAR TABEL.....	xiii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah.....	4
1.3 Batasan Masalah.....	4
1.4 Tujuan dan Manfaat Penelitian.....	5
1.5 Kontribusi Penelitian.....	5
BAB 2 TINJAUAN PUSTAKA DAN DASAR TEORI	7
2.1 Pertanian Tanaman Tebu.....	7
2.1.1. Varietas Tanaman Tebu	7
2.1.2. Fase Pertumbuhan Tebu.....	9
2.1.3. Sebaran Pertanian Tanaman Tebu.....	10
2.1.4. Rendemen dan Produksi Gula.....	13
2.2 Penyakit Karat Tebu.....	14
2.3 Penyakit Mosaik Tebu.....	15
2.4 Ekstraksi Fitur	16
2.5 Transformasi Citra.....	17
2.5.1. Transformasi Citra RGB Menjadi Citra Keabuan.....	18

2.5.2.	Transformasi Citra RGB ke LAB	18
2.6	Ekstraksi Fitur <i>Gray Level Co-occurrence Matrix</i>	21
2.7	Ekstraksi Fitur <i>Color moments</i>	24
2.8	Support Vector Machine	25
BAB 3 METODE PENELITIAN		27
3.1	Studi literatur	27
3.2	Analisis dan Perancangan	29
3.3	Implementasi.....	32
3.4	Uji Coba dan Evaluasi	32
3.5	Penulisan Laporan Penelitian.....	33
BAB 4 HASIL DAN PEMBAHASAN		35
4.1	Hasil Perancangan Sistem.....	35
4.1.1.	Pengumpulan data.....	35
4.1.2.	<i>Pre-processing</i> Citra.....	41
4.1.3.	Ekstraksi Fitur.....	43
4.1.4.	Klasifikasi	49
4.2	Tahapan Pengujian Sistem.....	49
4.3	Skenario Uji 1	51
4.3.1.	Hasil Uji Skenario 1	52
4.3.2.	Analisis Hasil Uji Skenario 1	52
4.4	Skenario Uji 2	53
4.4.1.	Hasil Uji Skenario 2	54
4.4.2.	Analisis Hasil Uji Skenario 2	54
4.5	Skenario Uji 3	55
4.5.1.	Hasil Uji Skenario 3	55
4.5.2.	Analisis Hasil Uji Skenario 3	56

4.6	Skenario Uji 4.....	56
4.6.1.	Hasil Uji Skenario 4.....	57
4.6.2.	Analisis Hasil Uji Skenario 4.....	57
BAB 5 KESIMPULAN DAN SARAN.....		59
5.1	Kesimpulan.....	59
5.2	Saran.....	59
DAFTAR PUSTAKA		61
LAMPIRAN.....		65
BIOGRAFI PENULIS		67

DAFTAR GAMBAR

Gambar 2.1 Tebu Varietas BL	8
Gambar 2.2 Tebu Varietas PSJK	9
Gambar 2.3 Fase Pertumbuhan Tebu	10
Gambar 2.4 Penyakit Karat pada Tebu	15
Gambar 2.5 Gejala Penyakit Mosaik pada Tebu.....	16
Gambar 2.6 Model RGB	19
Gambar 2.7 Diagram Kromasitas CIE	20
Gambar 2.8 Pemetaan Data pada SVM.....	26
Gambar 3.1 Alur Metode Penelitian	27
Gambar 3.2 Langkah Penelitian.....	29
Gambar 3.3 Arsitektur Sistem.....	30
Gambar 3.4 Metode Identifikasi Penyakit pada Daun Tebu	31
Gambar 4.1 Daun Tebu Normal.....	37
Gambar 4.2 Penyakit Karat	37
Gambar 4.3 Penyakit Mosaik.....	38
Gambar 4.4 Citra Hasil Pemisahan Tulang Daun	38
Gambar 4.5 Hasil Pemotongan Citra	39
Gambar 4.6 Hasil <i>Pre-processing</i> Citra	43
Gambar 4.7 Ilustrasi <i>Matriks Co-occurrence</i>	44
Gambar 4. 9 Alur Skenario Uji	50

DAFTAR TABEL

Tabel 2.1 Sebaran Pertanian Tebu	11
Tabel 2.2 Perbedaan Daun Tebu Normal dan Berpenyakit	16
Tabel 2.3 Kernel pada SVM	26
Tabel 4.1 Lokasi Pengambilan Data	35
Tabel 4.2 Jenis dan Spesifikasi Kamera	36
Tabel 4.3 Citra Karat.....	39
Tabel 4.4 Citra Mosaik	40
Tabel 4.5 Citra Normal	41
Tabel 4. 6 Penghitungan Statistik GLCM.....	44
Tabel 4. 7 Pengujian Akurasi per Fitur GLCM	45
Tabel 4.8 Analisis Statistik GLCM dan <i>Direction</i>	46
Tabel 4. 9 Akurasi Seluruh Fitur Tekstur	47
Tabel 4. 10 Penghitungan Color Moment.....	47
Tabel 4. 11 Pengujian Akurasi Per Fitur <i>Color Moments</i>	48
Tabel 4. 12 Pengujian Akurasi Kelompok dan Seluruh Fitur	48
Tabel 4.13 Elemen warna dan <i>color moment</i>	49
Tabel 4. 14 Skenario Uji	50
Tabel 4.15 Fitur Skenario Uji 1	51
Tabel 4.16 Akurasi Skenario Uji 1	52
Tabel 4.18 Hasil Akurasi per Fitur	53
Tabel 4.19 Fitur untuk Skenario Uji 2	53
Tabel 4.20 Akurasi Skenario Uji 2	54
Tabel 4.21 Fitur Skenario Uji 3	55
Tabel 4.22 Hasil Akurasi Skenario Uji 3	55
Tabel 4.23 Fitur Skenario 4	57
Tabel 4.24 Hasil Akurasi Skenario Uji 4.....	57

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Identifikasi penyakit tebu diperlukan dalam menunjang peningkatan produksi tebu yang dapat menghasilkan panen optimal dalam masa perubahan iklim global. Identifikasi penyakit tebu secara manual dilakukan dengan mengamati gejala yang tampak pada daun. Penyakit karat dapat dideteksi dari adanya bercak berwarna kuning sampai coklat pada daun (Raid, 2006). Gejala paling menonjol dari penyakit mosaik adalah perbedaan warna dari warna daun yang hijau (normal) dan adanya garis atau area *klorotik* berwarna hijau pucat sampai dengan kuning tua (Comstock, 2009).

Penyakit tanaman berkembang pesat sehingga diperlukan teknologi informasi untuk deteksi penyakit tanaman (Camargo, 2009b). Teknologi informasi mempermudah identifikasi penyakit tanaman karena tidak semua petani memiliki pemahaman detail tentang penyakit dan petani tidak perlu menghafal gejala penyakit yang merugikan dan tidak merugikan. Karat dan mosaik adalah penyakit yang menyerang tebu di Indonesia dan menimbulkan kerugian. Penyebaran penyakit karat tebu menyebabkan dampak ekonomi yang kuat karena berdampak pada penurunan panen. Penyakit karat pernah menyebabkan penurunan panen sebanyak 40% di Florida pada 1988 (Raid, 2006). Penyakit mosaik sering terjadi pada negara di mana tebu berkembang. Kerugian yang diperkirakan akibat penyakit mosaik beragam tergantung periode waktu dan seberapa luas daerah yang terserang. Penyakit mosaik pernah mengakibatkan collapse nya industri gula di Louisiana pada pertengahan tahun 1920 (Comstock, 2009).

Teknologi yang berkembang untuk identifikasi penyakit tanaman tebusaat ini berkembang dalam bidang penginderaan jauh antara lain (Apan, 2004) yang meneliti mengenai penyakit tebu di Australia, yaitu karat oranye dan mengevaluasi melalui EO-1 *hyperion imagery*. Penelitian (Abdel-Rahman, 2008) yang meneliti mengenai perkembangan teknologi penginderaan jauh yang bergerak dalam tanaman tebu. Penelitian (Grisham, 2010) menggunakan penginderaan jauh untuk deteksi penyakit daun kuning pada tebu.

Penelitian yang berkembang mengenai identifikasi penyakit tanaman dengan identifikasi citra digital daun berkembang dalam (Camargo, 2009a) tentang algoritma pengolahan citra untuk identifikasi penyakit tanaman yang gejalanya dapat dilihat secara visual. Penelitian (Camargo, 2009a) membahas mengenai tahap *pre-processing* citra daun dan lebih menekankan pada segmentasi untuk kemudian diteruskan pada penelitian selanjutnya (Camargo, 2009b). Penelitian (Camargo, 2009b) mengenai klasifikasi pola pada citra penyakit tanaman membahas identifikasi penyakit tanaman secara umum pada pisang, plantain, jagung, alfalfa, kapas dan kedelai. Penelitian tersebut menyatakan bahwa pola tetap identik meskipun *preliminary condition* (rotasi, translasi dan scale) berubah. Pemilihan fitur dianalisis melalui beberapa cara yaitu satu per satu, berdasarkan kelompok, dan seluruhnya kecuali satu fitur. Penelitian (Camargo, 2009b) menggunakan fitur bentuk (*solidity, extent, minor axis length, dan eccentricity*), tekstur (*contrast, correlation, energy, homogeneity, fractal dimension, dan lacunarity*) dan warna (histogram frekuensi dan *grey level* untuk masing-masing *channel* warna).

Penelitian (Asraf, 2012) mengenai studi perbandingan *kernel-based SVM* pada penyakit yang menyerang kelapa sawit yang disebabkan ketidakseimbangan nutrisi. Penelitian (Asraf, 2012) menggunakan fitur tekstur (histogram dan GLCM) dan warna (rata-rata RGB dan perbandingan nilai merah dan hijau dalam ruang warna RGB). Penelitian (Aduwo, 2012) membahas mengenai identifikasi penyakit mosaik pada singkong ditinjau dari citra digital daun. Penelitian (Aduwo, 2012) menggunakan fitur bentuk (*Scale Invariant Feature Transformation* dan *Speeded Up Robust Features*) dan warna (histogram warna dengan Hue pada ruang warna HSV).

Penelitian yang berkembang mengenai identifikasi penyakit tanaman tebu saat ini berkembang dalam bidang penginderaan jauh, sedangkan identifikasi penyakit tanaman melalui citra digital daun membahas mengenai penyakit tanaman secara umum oleh karena itu penelitian ini membahas mengenai pemilihan fitur yang tepat sehingga diharapkan cocok untuk identifikasi penyakit pada daun tebu. Penelitian ini tidak menggunakan fitur bentuk karena fitur bentuk lebih cocok untuk klasifikasi spesies tanaman dengan bentuk daun berbeda

(Shabanzade, 2011) dan identifikasi penyakit tanaman dengan gejala daun berlubang atau berubah bentuk di bagian tepi daun, misalnya pada penyakit mosaik pada daun singkong (Aduwo, 2012).

Terdapat perbedaan tekstur antara daun normal, berpenyakit karat dan mosaik (Raid, 2006; Comstock, 2009) sehingga perlu adanya ekstraksi fitur tekstur. Penelitian ini memilih *gray level co-occurrence matrix* untuk fitur tekstur karena GLCM sebagai fitur untuk mengetahui tekstur daun dipakai untuk deteksi spesies tanaman dan menghasilkan akurasi yang tinggi (Shabanzade, 2011), selain itu *co-occurrence matrix* memberikan hasil akurasi yang tinggi (83%) dibandingkan *fractal* (50%) dan *lacunarity* (52,13%) pada identifikasi penyakit tanaman ditinjau dari citra digital daun (Camargo, 2009). Kompleksitas tekstur citra sulit untuk didefinisikan dan dikuantifikasi, namun GLCM bisa dipakai untuk mengkuantifikasi dan membandingkan berbagai aspek tekstur citra (Honeycutt, 2008).

Penggunaan *color moments* untuk warna karena terdapat perbedaan warna pada daun normal dan berpenyakit (Raid, 2006) dan (Comstock, 2009). *Color moments* merupakan metode ekstraksi fitur yang efektif untuk analisis citra berdasarkan warna karena metode tersebut memiliki dimensi vektor fitur yang paling rendah dan juga kompleksitas komputasional yang paling rendah jika dibandingkan dengan metode lainnya seperti *color histogram*, *color correlogram* dan *color structure descriptor* (Patil, 2011). Beberapa penelitian untuk analisis penyakit tanaman melalui citra daun menghasilkan hasil yang baik saat menggunakan ekstraksi fitur warna dengan menggunakan nilai rata-rata RGB dan HSV (Camargo, 2009b dan Asraf, 2012). Penelitian (Daoliang Li, 2010) pada klasifikasi serat kapas juga menggunakan nilai rata-rata dan standar deviasi RGB.

Tahap awal penelitian adalah pengumpulan data citra daun tebu berpenyakit dari survei lapangan. Citra yang ditangkap kamera berada dalam format RGB. RGB tidak dapat merepresentasikan warna dalam persepsi manusia sehingga (Li-jie, 2009) menggunakan $L^*a^*b^*$ untuk segmentasi citra. Oleh karena itu, ruang warna yang digunakan dalam penelitian ini diubah dari RGB ke $L^*a^*b^*$. Tahap selanjutnya adalah *pre-processing* citra untuk dapat diolah pada tahap

ekstraksi fitur. Pada tahap ekstraksi fitur, fitur tekstur diekstraksi dengan GLCM dan fitur warna diekstraksi dengan *color moments*.

Klasifikasi daun tebu berpenyakit dilakukan berdasarkan fitur yang telah diekstraksi pada tahap sebelumnya. Penelitian ini menggunakan metode *support vector machine* (SVM) karena SVM cocok untuk klasifikasi yang datanya sedikit (Li, 2010). Selain itu SVM memberikan hasil akurasi yang tinggi untuk analisis penyakit tanaman (Camargo, 2009b; Asraf, 2012). Strategi pengujian dilakukan untuk mengetahui fitur yang kemunculannya menyebabkan perubahan dalam hasil klasifikasi, yaitu dengan menguji sebuah fitur, per kelompok fitur, seluruh fitur kecuali satu fitur, kemudian seluruh fitur.

Berdasarkan paparan masalah mengenai kebutuhan identifikasi penyakit pada daun tebu melalui analisis citra digital daun, penelitian ini membentuk metode identifikasi penyakit melalui GLCM dan *color moments*. Penelitian mengenai identifikasi penyakit tanaman ditinjau dari citra digital daun (Camargo, 2009) menyarankan penggunaan fitur bentuk, tekstur dan warna. Pada penelitian dilakukan penghapusan fitur bentuk, fitur tekstur dengan *gray level co-occurrence matrix* dan fitur warna dengan *color moments* sehingga diharapkan cocok untuk identifikasi penyakit pada daun tebu.

1.2 Perumusan Masalah

Perumusan masalah dalam penelitian ini sebagai berikut:

1. Bagaimana pengaruh ekstraksi fitur *gray level co-occurrence matrix* terhadap klasifikasi citra digital daun tebu.
2. Bagaimana pengaruh ekstraksi fitur *color moments* terhadap klasifikasi citra digital daun tebu.
3. Bagaimana pengaruh ekstraksi fitur paduan antara *gray level co-occurrence matrix* dan *color moments* terhadap klasifikasi citra digital daun tebu.

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini sebagai berikut:

1. Sistem disimulasikan menggunakan MATLAB R2011b.

2. Penyakit tebu yang diteliti adalah mosaik dan karat.
3. Metode klasifikasi yang digunakan dalam penelitian ini adalah *Support Vector Machine* (SVM) dengan kernel *linear*.

1.4 Tujuan dan Manfaat Penelitian

Tujuan dari penelitian ini adalah membentuk metode identifikasi penyakit pada daun tebu melalui GLCM dan *color moments*. Manfaat penelitian ini adalah metode yang diusulkan dapat digunakan untuk identifikasi penyakit pada daun tebu.

1.5 Kontribusi Penelitian

Kontribusi penelitian ini adalah metode untuk identifikasi penyakit tebu melalui citra digital daun dengan *gray level co-occurrence matrix* dan *color moments*.

BAB 2

TINJAUAN PUSTAKA DAN DASAR TEORI

Tinjauan pustaka memuat dasar teori penelitian yang meliputi pertanian tanaman tebu, penyakit karat tebu, penyakit mosaik tebu, ekstraksi fitur *gray level co-occurrence matrix* (GLCM), ekstraksi fitur *color moments* dan metode klasifikasi *support vector machine* (SVM).

2.1 Pertanian Tanaman Tebu

Tanaman tebu sebagai komoditas Indonesia memberi peranan penting dalam bidang perekonomian karena pertanian tanaman tebu tersebar di banyak daerah di wilayah Indonesia. Hal yang berkaitan dengan pertanian tanaman tebu di Indonesia meliputi varietas tanaman tebu, fase pertumbuhan tebu, sebaran tanaman tebu serta produksi gula di Indonesia.

2.1.1. Varietas Tanaman Tebu

Tebu (*Saccharum Officinarum L*) merupakan tanaman perkebunan satu musim yang batangnya terdapat zat gula sehingga dapat dimanfaatkan sebagai bahan baku gula dan vetsin. Tebu termasuk keluarga rumput-rumputan (*gramineae*). Varietas tebu pada garis besarnya dapat dibedakan menjadi 3, yaitu:

- a) Varietas Genjah (masak awal), mencapai masak optimal < 12 bulan.
- b) Varietas Sedang (masak tengahan), mencapai masak optimal pada umur 12-14 bulan.
- c) Varietas Dalam (masak akhir), mencapai masak optimal pada umur lebih dari 14 bulan.

Varietas tebu yang diteliti dalam penelitian ini adalah BL dan PSJK 922. Varietas PSJK termasuk varietas genjah (masak awal) sedangkan varietas BL merupakan varietas tebu dalam (masak akhir).

Varietas tebu BL tahan terhadap penyakit mosaik dan blendok, namun agak peka terhadap penyakit pohkabung dan serangan hama penggerek pucuk. Potensi produktivitas varietas BL ini dapat mencapai sekitar 121,4 kuintal gula per hektar (Rizaldi, 2014).

Potensi pada lahan sawah dengan ekologi unggulan yang menggunakan BL dapat mencapai produksi tebu 1.504 kuintal per hektar (tertinggi 2.093 kuintal). Potensi pada lahan tegal juga menunjukkan hasil tebu rata-rata 1.250 kuintal per hektar (tertinggi 2.112 kuintal).

Potensi pada pola keprasan menunjukkan varietas BL juga menunjukkan hasil yang cukup menjanjikan. Dari uji coba dihasilkan tebu rata-rata 1.222 kuintal per hektar (Rizaldi, 2014).

Batang tebu BL berbentuk silindris dengan warna cokelat kemerahan. Cincin tumbuh melingkar datar di atas pucuk mata. Warna daun hijau dan ukuran daun panjang melebar. Pada bekas pangkal pelepah daun terdapat mata yang berbentuk segitiga. Gambar berikut adalah batang, daun dan mata tebu varietas BL (P3GI, 2009).




Gambar 2.1 Tebu Varietas BL

Sumber: P3GI, 2009

Varietas PSJK 922 adalah varietas yang tergolong baru melalui SK Menteri Pertanian No. 577/Kpts/SR.120/2/2012. Varietas ini sesuai untuk lahan sawah dan tegal dengan potensi produksi gula 1.400 kuintal per hektar.

Batang PSJK berwarna hijau kekuningan dengan ruas lurus sampai berbuku. Warna daun hijau dengan bentuk ujung daun melengkung. Pada pangkal pelepah daun bagian atas terdapat mata tebu. Gambar berikut adalah contoh daun PSJK 922 yang diambil dari survey lapangan.



Gambar 2.2 Tebu Varietas PSJK

Sumber: Dasar Teori

2.1.2. Fase Pertumbuhan Tebu

Tebu mengalami fase pertumbuhan yang sering disebut sebagai siklus hidup tebu (Rizaldi, 2014). Siklus ini terdiri dari 5 fase, yaitu:

1) Fase Perkecambahan

Fase ini dimulai dengan pembentukan taji pendek dan akar stek pada umur 1 minggu dan diakhiri pada fase kecambah pada umur 5 minggu.

2) Fase Pertunasan

Fase ini dimulai dari umur 5 minggu sampai umur 3,5 bulan.

3) Fase Pemanjangan Batang

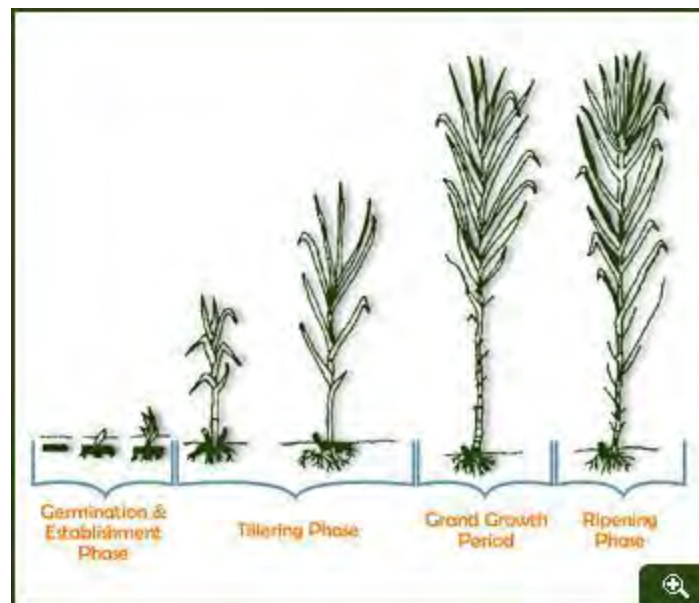
Fase ini dimulai pada umur 3,5 bulan sampai 9 bulan.

4) Fase Kemasakan

Fase ini merupakan fase yang terjadi setelah pertumbuhan vegetatif menurun dan sebelum batang tebu mati. Pada fase ini gula didalam batang tebu mulai terbentuk hingga titik optimal, kurang lebih terjadi pada bulan Agustus, dan setelah itu rendemennya berangsur-angsur menurun. Tahap pemasakan inilah yang disebut dengan tahap penimbunan rendemen gula.

5) Fase Kematian

Gambar berikut adalah penjelasan detail mengenai fase pertumbuhan tebu:



Gambar 2.3 Fase Pertumbuhan Tebu

Sumber: Agropedia, 2014

Fase perkecambahan adalah perubahan mata tunas menjadi kecambah atau biasa disebut tunas tebu muda. Fase selanjutnya adalah fase pertunasan yaitu proses keluarnya anakan dari pangkal tebu muda. Pertunasan yang baik terjadi jika setiap rumpun terdiri dari 1 batang induk dengan 4-6 tunas anakan. Fase ketiga adalah perpanjangan batang dimana biomassa tebu bertambah dan daun juga bertambah banyak. Pada fase ini batang membesar dengan menumbuhkan ruas. Fase kemasakan dikenal sebagai fase pengisian gula karena proses pengisian gula hasil fotosintesis yang terjadi lebih besar daripada perombakan gula. Fase terakhir adalah fase kematian yang ditandai tebu mulai kekurangan nira dan air dalam tubuhnya sehingga berat dan rendemennya menurun (Agropedia, 2014).

2.1.3. Sebaran Pertanian Tanaman Tebu

Pertanian tanaman tebu tersebar di banyak daerah di wilayah Indonesia, antara lain Sumatra, Jawa, Kalimantan dan Sulawesi. Berikut adalah tabel lokasi pabrik gula beserta kapasitas gula yang dapat dihasilkan (Rizaldi, 2014):

Tabel 2.1 Sebaran Pertanian Tebu

No.	Nama Perusahaan	Lokasi	Kapasitas Volume (Ton/hari)
SUMATERA UTARA			
1	PG. Kwala Madu	Binjai	3,941
2	PG. Sei Semayang	Deli Serdang	3,998
SUMATERA SELATAN			
3	PG. Cinta Manis	Ogan Komering Ilir	5,023
LAMPUNG			
4	PG. Bunga Mayang	Lampung Utara	5,979
5	PG. Gunung Madu	Lampung Tengah	11,432
6	PG. Gula Putih Mataram	Lampung Tengah	12,124
7	PG. Sweet Indo Lampung	Lampung Utara	10,539
JAWA BARAT			
8	PG. Kadipaten	Majalengka	1,171
9	PG. Jatiwangi	Majalengka	1,050
10	PG. Gempol	Cirebon	1,200
11	PG. Sindanglaut	Cirebon	1,780
12	PG. Karang Suwung	Cirebon	1,334
13	PG. Tersana Baru	Cirebon	3,015
14	PG. Jatitujuh	Majalengka	4,045
15	PG. Subang	Subang	2,852
JAWA TENGAH			
16	PG. Banjarnegara	Brebes	2,000
17	PG. Jatibarang	Brebes	2,000
18	PG. Pangka	Tegal	1,772
19	PG. Sumberharjo	Pemalang	1,798
20	PG. Sragi	Pekalongan	3,184
21	PG. Cepiring	Kendal	1,750
22	PG. Rendeng	Kudus	2,520
23	PG. Mojo	Sragen	2,726
24	PG. Tasikmadu	Karanganyar	3,218
25	PG. Colomadu	Karanganyar	1,300
26	PG. Ceperbaru	Klaten	1,350
27	PG. Gondangbaru	Klaten	1,452
28	PG. Kalibagor	Banyumas	1,250
29	PG. Pakisbaru	Pati	2,765
30	PG. Trangkil	Pati	3,267
D.I. YOGYAKARTA			
31	PG. Madukismo	Bantul	3,100
JAWA TIMUR			
32	PG. Krian	Sidoarjo	1,500

33	PG. Watutulis	Sidoarjo	2,085
34	PG. Tulangan	Sidoarjo	1,287
35	PG. Krembong	Sidoarjo	1,446
36	PG. Gempolperet	Mojokerto	5,742
37	PG. Jombangbaru	Jombang	2,187
38	PG. Cukir	Jombang	2,897
39	PG. Lestari	Nganjuk	3,529
40	PG. Merican	Kediri	2,515
41	PG. Pesantren Baru	Kediri	5,607
42	PG. Ngadirejo	Kediri	5,615
43	PG. Mojopanggung	Tulungagung	2,521
44	PG. Sudono	Ngawi	2,289
45	PG. Purwodadi	Magetan	1,946
46	PG. Rejosari	Magetan	1,814
47	PG. Pagottan	Madiun	2,084
48	PG. Kanigoro	Madiun	1,729
49	PG. Kedawung	Pasuruan	2,194
50	PG. Wonolangan	Probolinggo	1,199
51	PG. Gending	Probolinggo	1,305
52	PG. Pajarakan	Probolinggo	1,117
53	PG. Jatiroto	Lumajang	5,762
54	PG. Semboro	Jember	4,515
55	PG. Pe Maas	Situbondo	838,000
56	PG. Wringinanom	Situbondo	1,084
57	PG. Olean	Situbondo	963,000
58	PG. Panji	Situbondo	1,573
59	PG. Asembagus	Situbondo	2,365
60	PG. Prajekan	Bondowoso	2,532
61	PG. Rejoagung Baru	Malang	3,900
62	PG. Kreber Baru	Malang	7,000
63	PG. Candi	Sidoarjo	1,700
64	PT. Tri Guna Gina	Malang	3,698
KALIMANTAN SELATAN			
65	PG. Pelaihari	Tanah Laut	3,862
SULAWESI UTARA			
66	PG. Tolangohula	Gorontalo	8,000
SULAWESI SELATAN			
67	PG. Bone	Bone	2,194
68	PG. Camming	Bone	2,517
69	PG. Takalar	Takalar	2,842

Sumber: Rizaldi, 2014

Dari tabel tersebut dapat disimpulkan bahwa Jawa Timur merupakan produsen gula terbesar di Indonesia. Pada penelitian ini, perkebunan tebu yang diteliti berada di Jawa Timur, lebih tepatnya di Malang.

2.1.4. Rendemen dan Produksi Gula

Peningkatan produksi gula dapat dilaksanakan dengan perluasan area, peningkatan bobot tebu per hektar dan peningkatan rendemen (P3GI, 2008). Pilihan paling baik adalah peningkatan rendemen karena kinerja rendemen selama lima tahun terakhir hampir hanya separuh dari yang pernah dicapai sebelum tahun 1975.

Rendemen tebu adalah kadar kandungan gula didalam batang tebu yang dinyatakan dengan persen. Bila dikatakan rendemen tebu 10 %, artinya ialah dari 1000 kg tebu yang digilingkan akan diperoleh gula sebanyak 100 kg. Ada 3 cara penghitungan rendemen, yaitu: rendemen contoh, rendemen sementara, dan rendemen efektif (Rizaldi, 2014).

1. Rendemen Contoh

Rendemen ini merupakan contoh yang dipakai untuk mengetahui apakah suatu kebun tebu sudah mencapai masak optimal atau belum. Dengan kata lain rendemen contoh adalah untuk mengetahui gambaran suatu kebun tebu berapa tingkat rendemen yang sudah ada sehingga dapat diketahui saat tebang yang tepat dan kapan tanaman tebu mencapai tingkat rendemen yang memadai.

$$\text{Nilai nira} \times \text{Faktor rendemen} = \text{Rendemen} \quad (2.1)$$

2. Rendemen Sementara

Perhitungan rendemen sementara digunakan dalam menentukan bagi hasil gula, tetapi sifatnya masih sementara. Hal ini dilakukan agar penentuan bagi hasil gula dilakukan segera setelah tebu petani digiling sehingga petani tidak menunggu terlalu lama sampai selesai giling.

Cara mendapatkan rendemen sementara ini adalah dengan mengambil nira perahan pertama tebu yang digiling untuk dianalisis di laboratorium untuk mengetahui berapa besar rendemen sementara tersebut.

$$\text{Rendemen Sementara} = \text{Faktor Rendemen} \times \text{Nilai Nira}. \quad (2.2)$$

3. Rendemen Efektif

Rendemen efektif adalah rendemen hasil perhitungan setelah tebu digiling habis dalam jangka waktu tertentu. Rendemen ini sering disebut rendemen nyata. Perhitungan rendemen efektif ini dapat dilaksanakan dalam 1 periode giling sehingga apabila pabrik gula mempunyai hari giling 170 hari, maka jumlah periode giling adalah $170/15 = 12$ periode. Hal ini berarti terdapat 12 kali rendemen nyata atau efektif yang bisa diperhitungkan dan diberitahukan kepada petani tebu.

Peningkatan rendemen akan meningkatkan produktivitas produksi gula tanpa meningkatkan jumlah pabrik gula. Peningkatan rendemen dapat dilakukan dengan beragam cara, antara lain:

1. Pemilihan varietas dan pembibitan
2. Pengaturan waktu untuk menanam dan kebutuhan air
3. Melakukan pemupukan yang baik danimbang
4. Pengendalian hama dan penyakit
5. Strategi penentuan waktu awal giling
6. Pengawasan dalam tebang, muat dan angkut

Upaya peningkatan rendemen salah satunya adalah pengendalian hama dan penyakit tanaman tebu. Pada penelitian ini akan diteliti penyakit pada daun tebu, yaitu penyakit karat dan mosaik.

2.2 Penyakit Karat Tebu

Penyakit karat tebu disebabkan oleh jamur *Puccinia Melanocephala*. Jamur tersebut kini ditemukan hampir di setiap area dimana tebu tumbuh. Penyebaran penyakit ini menyebabkan dampak ekonomi yang kuat. Penyakit karat adalah penyakit yang gejalanya dapat dilihat dari daun. Gejala awal penyakit ini adalah bercak kecil berwarna kuning, kemudian menjadi semakin besar dan dapat menjadi berwarna coklat. Lesi dari penyakit karat berkisar antara panjang 2-10 mm, bahkan kadang dapat mencapai 30 mm. Lebar lesi penyakit karat antara 1-3 mm (Raid, 2006).



Gambar 2.4 Penyakit Karat pada Tebu

Sumber: Raid, 2006

Penyakit karat tebu yang parah dapat menyebabkan kematian dini pada daun tebu muda. Penyakit ini dapat mengurangi massa batang beserta jumlahnya. Hal tersebut menjadikan tebu berkurang bobotnya saat ditimbang. Jamur pathogen penyakit karat hanya menginfeksi jaringan tebu yang masih hidup. Penyebaran penyakit ini adalah melalui spora yang terbawa melalui udara. Asal mula penyakit karat tebu di Amerika berasal dari Afrika dengan penyebaran spora melalui angin. Kelembaban daun dan suhu udara adalah faktor lingkungan yang berpengaruh terhadap perkembangan penyakit karat tebu. Hujan sebenarnya meningkatkan kelembaban daun tetapi spora jamur akan berpindah ikut terbawa hujan sehingga hujan bukan faktor yang meningkatkan perkembangan penyakit karat tebu (Raid, 2006).

2.3 Penyakit Mosaik Tebu

Penyakit yang disebabkan oleh *sugarcane mosaic virus* (SCMV) sering disebut mosaik. Penyakit mosaik sering terjadi pada negara di mana tebu berkembang. Kerugian yang diperkirakan akibat penyakit mosaik beragam tergantung periode waktu dan seberapa luas daerah yang terserang. Penyakit mosaik pernah menjadi masalah serius di Louisiana yang menyebabkan keruntuhan perindustrian tebu pada pertengahan tahun 1920 (Comstock, 2009).



Gambar 2.5 Gejala Penyakit Mosaik pada Tebu

Sumber: Comstock, 2009

Penyakit mosaik dapat teridentifikasi dari gejala yang muncul dari daun. Gejala paling menonjol dari penyakit mosaik adalah perbedaan warna dari warna daun yang hijau (normal) menjadi adanya garis atau area *klorotik* berwarna hijau pucat sampai dengan kuning tua. Infeksi penyakit ini dapat pula menjadikan daun berwarna merah. Penyakit ini lebih mudah menginfeksi tanaman muda yang sedang berkembang daripada tanaman tebu dewasa dengan tingkat pertumbuhan yang lebih rendah (Comstock, 2009).

2.4 Ekstraksi Fitur

Berdasarkan deskripsi penyakit karat dan mosaik pada tebu, ciri yang tampak antara daun sehat dan berpenyakit dijelaskan secara detail pada Tabel 2.1 berikut:

Tabel 2.2 Perbedaan Daun Tebu Normal dan Berpenyakit

	Normal	Karat	Mosaik	Metode Ekstraksi Fitur
Tekstur	Tidak ada bercak maupun garis	Adanya bercak	Adanya garis	GLCM
Warna	Seluruh area berwarna hijau	Bercak berwarna kuning sampai coklat	Garis berwarna hijau pucat sampai kuning tua	<i>Color moments</i>

Terdapat perbedaan tekstur antara daun normal, berpenyakit karat dan mosaik (Raid, 2006; Comstock, 2009) sehingga perlu adanya ekstraksi fitur tekstur. Penelitian ini memilih *gray level co-occurrence matrix* untuk fitur tekstur karena GLCM sebagai fitur untuk mengetahui tekstur daun dipakai untuk deteksi spesies tanaman dan menghasilkan akurasi yang tinggi (Shabanzade, 2011), selain itu *co-occurrence matrix* memberikan hasil akurasi yang tinggi (83%) dibandingkan *fractal* (50%) dan *lacunarity* (52,13%) pada identifikasi penyakit tanaman ditinjau dari citra digital daun (Camargo, 2009). Kompleksitas tekstur citra sulit untuk didefinisikan dan dikuantifikasi, namun GLCM bisa dipakai untuk mengkuantifikasi dan membandingkan berbagai aspek tekstur citra (Honeycutt, 2008).

Penggunaan *color moment* untuk warna karena terdapat perbedaan warna pada daun normal dan berpenyakit (Raid, 2006) dan (Comstock, 2009). *Color moments* merupakan metode ekstraksi fitur yang efektif untuk analisis citra berdasarkan warna karena metode tersebut memiliki dimensi vektor fitur yang paling rendah dan juga kompleksitas komputasional yang paling rendah jika dibandingkan dengan metode lainnya seperti *color histogram*, *color correlogram* dan *color structure descriptor* (Patil, 2011). Beberapa penelitian untuk analisis penyakit tanaman melalui citra daun menghasilkan hasil yang baik saat menggunakan ekstraksi fitur warna dengan menggunakan nilai *grey level* pada masing-masing *channel* warna (Camargo, 2009b dan Asraf, 2012). Penelitian (Daoliang Li, 2010) pada klasifikasi serat kapas juga menggunakan nilai rata-rata dan standar deviasi RGB.

2.5 Transformasi Citra

Tahap *pre-processing* dalam penelitian ini bertujuan memudahkan penghitungan pada tahap ekstraksi fitur. Citra yang diambil kamera berada dalam format RGB. Oleh karena itu, perlu adanya transformasi warna dari RGB menjadi citra keabuan untuk dapat diproses dalam ekstraksi fitur GLCM dan transformasi warna dari RGB menjadi LAB untuk dapat diproses dalam ekstraksi fitur *color moment* 1,2, dan 3.

2.5.1. Transformasi Citra RGB Menjadi Citra Keabuan

Citra warna dapat diubah menjadi citra keabuan dengan metode penghitungan *lightness* dan *average*. Metode *luminosity* merupakan pengembangan dari metode *lightness* dan *average*. Metode ini menghitung nilai setiap elemen warna, yaitu Red, Green, dan Blue dengan menambahkan bobot sesuai persepsi penglihatan manusia. Secara matematis, perhitungan untuk konversi citra warna menjadi citra keabuan dapat dirumuskan sebagai berikut:

a) *Lightness*

Metode ini menghitung nilai maksimal serta minimal *R*, *G* dan *B* kemudian menghitung rata-ratanya.

$$\textit{Lightness} = (\max(R, G, B) + \min(R, G, B)) / 2 \quad (2.3)$$

b) *Average*

Metode ini menghitung rata-rata setiap elemen warna, yaitu *Red*, *Green*, dan *Blue*.

$$\textit{Average} = (R + G + B) / 3. \quad (2.4)$$

c) *Luminosity*

Metode ini menghitung nilai setiap elemen warna, yaitu *Red*, *Green*, dan *Blue* dengan menambahkan bobot sesuai persepsi penglihatan manusia. Penglihatan manusia lebih sensitif terhadap warna hijau oleh karena itu elemen warna *G* memiliki bobot yang paling tinggi dari elemen warna lainnya (Mathworks, 2014).

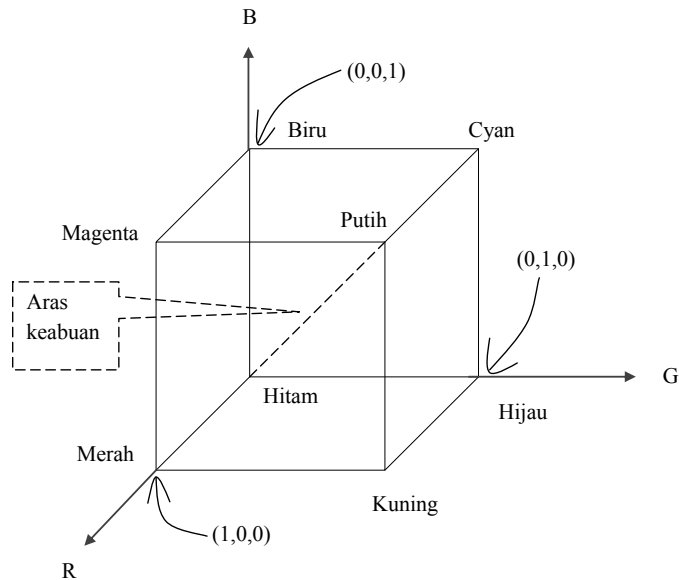
$$\textit{Luminosity} = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (2.5)$$

Penelitian ini menggunakan metode *luminosity* untuk transformasi citra RGB menjadi citra keabuan karena metode ini lebih dekat ke persepsi penglihatan manusia.

2.5.2. Transformasi Citra RGB ke LAB

RGB adalah ruang warna standar yang dipakai perangkat *input* seperti kamera digital dan *scanner* untuk perekaman citra, dan perangkat *output* seperti

layar monitor untuk menampilkan citra. RGB (*Red, Green, Blue*) adalah ruang warna yang direpresentasikan dalam ruang berbentuk kubus yang memiliki tiga komponen warna yakni *Red* (merah), *Green* (hijau), *Blue* (biru). Model RGB biasa disajikan dalam bentuk kubus tiga dimensi, dengan warna merah, hijau, dan biru berada pada pojok sumbu. Warna hitam berada pada titik asal dan warna putih berada di ujung kubus yang berseberangan (Kadir, 2014)




Gambar 2.6 Model RGB

Sumber: Kadir, 2014

RGB tidak dapat merepresentasikan warna dalam persepsi manusia sehingga (Li-jie, 2009) menggunakan LAB untuk segmentasi citra. Ruang warna ini mendeskripsikan persepsi mata manusia dalam melihat atribut warna (Zhang, 2008) yakni *hue*, *brightness*, dan *saturation*.

CIELAB direpresentasikan dalam ruang berbentuk bola. CIELAB adalah nama lain dari CIE $L^*a^*b^*$. Diagram kromasitas CIE (Commission Internationale de L'Eclairage) ditunjukkan pada Gambar 2.7. Pada diagram tersebut, setiap perpaduan x dan y menyatakan suatu warna. Namun, hanya warna yang berada dalam area ladam (tapal kuda) yang bisa terlihat. Angka yang berada di tepi menyatakan panjang gelombang cahaya. Warna yang terletak di dalam segitiga menyatakan warna-warna umum di monitor CRT, yang dapat dihasilkan oleh komponen warna merah, hijau, dan biru.



Gambar 2.7 Diagram Kromasitas CIE

Sumber: Kadir, 2014

Warna dari sebuah pixel pada citra didefinisikan oleh $[C_0, C_1, C_2]$ dimana C adalah komponen dari suatu ruang warna. Transformasi ruang warna adalah fungsi yang dapat mengkonversi dari $[C_0, C_1, C_2]$ menjadi $[C_0', C_1', C_2']$. Transformasi ruang warna RGB ke CIELAB memiliki dua tahapan yang dijelaskan oleh rumus (2.6) untuk transformasi ruang warna RGB ke CIE XYZ, dan rumus (2.7), (2.8), (2.9) untuk transformasi dari XYZ ke CIELAB (Kadir, 2014).

1. Transformasi ruang warna *RGB* ke *XYZ*

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,412453 & 0,357580 & 0,180423 \\ 0,212671 & 0,715160 & 0,072169 \\ 0,019334 & 0,119193 & 0,950227 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.6)$$

2. Transformasi dari *XYZ* menjadi *LAB* mengikuti persamaan seperti berikut:

$$L = 116 \times f\left(\frac{Y}{Y_w}\right) - 16 \quad (2.7)$$

$$a^* = 500 \left[f\left(\frac{X}{X_w}\right) - f\left(\frac{Y}{Y_w}\right) \right] \quad (2.8)$$

$$b^* = 200 \left[f\left(\frac{Y}{Y_w}\right) - f\left(\frac{Z}{Z_w}\right) \right], \quad (2.9)$$

Dimana $f(t) = t^{1/3}$ untuk $t > 0.008856$ dan $f(t) = 7.787 \times t + 16/116$ untuk $t \leq 0.008856$. XYZ merepresentasikan referensi standar untuk nilai tristimulus warna putih berdasarkan CIE55 yang didefinisikan oleh $x = 0.3324$ dan $y = 0.3474$.

2.6 Ekstraksi Fitur Gray Level Co-occurrence Matrix

Ada 3 pendekatan untuk analisis tekstur yaitu spektral, struktural dan statistikal. Spektral, misalnya Fourier, memiliki performa yang baik pada tekstur yang periodik tapi akan memburuk jika teksturnya tidak periodik, selain itu metode ini memiliki kompleksitas komputasional yang tinggi. Pendekatan struktural memiliki performa yang baik pada pola deterministik, tetapi tekstur mayoritas yang dihitung pada keseluruhan citra bukanlah penghitungan geometri yang tepat, melainkan *behavior* random yang tidak tentu. Pendekatan statistikal, misalnya GLCM, banyak digunakan untuk berbagai aplikasi (Gadelmawla, 2004).

Gray level co-occurrence matrix (GLCM) adalah metode untuk mengekstraksi fitur tekstur. GLCM adalah matriks yang dibangun menggunakan histogram tingkat kedua (Albregtsen, 2008). Ketergantungan spasial dari *gray level* dihitung dengan 14 fitur dari co-occurrence matrix (Haralick, 1973).

Jika G_{ij} adalah jumlah berapa kali piksel dengan tingkat keabuan i terjadi berdampingan dengan tingkat keabuan j dan n adalah jumlah pasangan piksel maka P_{ij} yang merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j dapat dihitung dengan membagi G_{ij} dengan n . Penghitungan piksel yang berdampingan memiliki arah dan jarak, arah sesuai sudut 0^0 , 45^0 , 90^0 , dan 135^0 dan jarak adalah jarak antar piksel, misalnya 1 atau 2. Penghitungan statistik GLCM yang digunakan dalam penelitian ini menggunakan P_{ij} sebagai dasar penghitungan dapat dijelaskan sebagai berikut:

1. *Contrast*

Contrast yang merupakan *variance* dari *gray level* (Kekre, 2010), adalah pengukuran untuk perbedaan nilai kontras dari sebuah pixel dan tetangganya yang dihitung untuk semua piksel pada citra (Shabanzade, 2011). Untuk 1 sampai k jumlah piksel dalam sebuah citra, jika P_{ij} merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j ,

maka $f1$ yang merupakan komponen *contrast* dari GLCM dapat dihitung sebagai berikut:

$$f1 = \sum_{i=1}^k \sum_{j=1}^k (i - j)^2 P_{ij} \quad (2.10)$$

2. Energy

Energy adalah pengukuran intensitas keseragaman piksel (Honeycutt, 2008). Sebuah keadaan homogen mengandung hanya sedikit gray level tetapi memiliki nilai piksel P_{ij} yang tinggi, oleh karena itu jumlah dari pangkat P_{ij} akan tinggi (Albregtsen, 2008). Untuk 1 sampai k jumlah piksel dalam sebuah citra, jika P_{ij} merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j , maka $f3$ yang merupakan komponen *energy* dari GLCM dapat dihitung sebagai berikut:

$$f2 = \sum_{i=1}^k \sum_{j=1}^k P_{ij}^2 \quad (2.11)$$

3. Homogeneity

Adalah kesamaan (*similarity*) dari *cooccurrence matrix* dan diagonal *matrix* (Shabanzade, 2011). Untuk 1 sampai k jumlah piksel dalam sebuah citra, jika P_{ij} merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j , maka $f3$ yang merupakan komponen *homogeneity* dari GLCM dapat dihitung sebagai berikut:

$$f3 = \sum_{i=1}^k \sum_{j=1}^k \frac{P_{ij}}{1+|i-j|} \quad (2.12)$$

4. Entropy

Entropy adalah rasio randomisasi pada citra yang dapat dihitung sebagai berikut (Mohanaiah, 2013). Citra yang tidak homogen memiliki nilai *first order entropy* yang rendah, sebaliknya maka nilai *entropy* tinggi (Albregtsen, 2008). Untuk 1 sampai k jumlah piksel dalam sebuah citra, jika P_{ij} merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j , maka $f4$ yang merupakan komponen *entropy* dari GLCM dapat dihitung sebagai berikut:

$$f4 = - \sum_{i=1}^k \sum_{j=1}^k P_{ij} \log_2(P_{ij}) \quad (2.13)$$

5. Variance

Pengukuran ini mengukur heterogenitas dan berkorelasi dengan standar deviasi. Untuk 1 sampai k jumlah piksel dalam sebuah citra, jika P_{ij} merupakan

distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j , maka *variance* dapat dihitung:

$$f5 = \sum_i \sum_j (i - \mu)^2 P_{ij} \quad (2.14)$$

6. *Correlation*

Pengukuran ini menunjukkan ketergantungan linear *gray tone* pada citra. Untuk 1 sampai k jumlah piksel dalam sebuah citra, jika P_{ij} merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j , maka *correlation* dapat dihitung:

$$f6 = \frac{\sum_i \sum_j P_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2.15)$$

Fitur GLCM berikutnya diturunkan dari 6 fitur GLCM di atas, dengan keterangan variabel yang sama, fitur GLCM lainnya dapat dihitung sebagai berikut:

7. *Sum Average*

$$f7 = \sum_{i=2}^{2Np} i P_{x+y}(i) \quad (2.16)$$

8. *Sum Entropy*

$$f8 = - \sum_{i=2}^{2Np} P_{x+y}(i) \log\{P_{x+y}(i)\} \quad (2.17)$$

9. *Sum Variance*

$$f9 = \sum_{i=2}^{2Np} (i - f6)^2 P_{x+y}(i) \quad (2.18)$$

10. *Difference Variance*

$$f10 = \text{variance}(P_{x-y}) \quad (2.19)$$

11. *Difference Entropy*

$$f11 = - \sum_{i=2}^{2Np} P_{x-y}(i) \log\{P_{x-y}(i)\} \quad (2.20)$$

12. *Information Measure of Correlation 1*

$$f12 = \frac{H_{XY} - H_{XY1}}{\max\{H_X, H_Y\}} \quad (2.21)$$

13. *Information Measure of Correlation 2*

$$f13 = \sqrt{(1 - \exp[-2.0(HXY2 - HXY)])} \quad (2.22)$$

14. *Maximum Correlation Coefficient*

$$f14 = 2nd \text{ eigen value } \sum_k \frac{P(i,k)P(j,k)}{P_x(i)P_y(k)} \quad (2.23)$$

2.7 Ekstraksi Fitur *Color moments*

Warna adalah fitur penting yang banyak digunakan representasi citra. Fitur warna pada citra dapat digali dengan beragam metode antara lain *color histogram*, *color correlogram*, *color moment* dan *color structure descriptor*. *Color moments* memiliki dimensi vektor fitur yang paling kecil diantara beragam metode lainnya dan juga memiliki kompleksitas komputasi yang paling kecil (Patil, 2011). Oleh karena itu, *color moments* merupakan parameter yang tepat untuk digunakan dalam proses klasifikasi.

Color moments adalah metode pengukuran yang dapat digunakan untuk membedakan citra berdasarkan fitur warna. Dasar *color moments* adalah bahwa distribusi warna pada citra dapat diinterpretasikan sebagai probabilitas distribusi. Jika warna pada citra mengikuti probabilitas distribusi tertentu, maka *moment* dari distribusi tersebut dapat digunakan sebagai fitur untuk identifikasi citra berdasarkan warna (Herdiyeni, 2012). Pada proses ekstraksi fitur, *color moments* menggunakan 3 moment penting sebagai berikut:

a) *Color Moment 1*

Mean merupakan rata-rata nilai piksel (P_{ij}) pada masing-masing channel warna (Kodituwakku, 2011). *Mean* digunakan untuk merepresikan nilai rata-rata piksel pada masing-masing channel warna dan memberikan ukuran mengenai distribusi. Jika P_{ij} merupakan piksel j pada channel warna i dan N adalah penjumlahan dari seluruh piksel pada citra, maka *mean* yang merupakan moment pertama dalam *color moments* dapat dihitung sebagai berikut:

$$\mu = \frac{1}{N} \sum_{i=1}^N P_{ij} \quad (2.24)$$

b) *Color Moment 2*

Standar deviasi adalah akar dari *variance*. *Variance* menyatakan luas sebarandistribusi. Standar deviasi dihitung dengan persamaan berikut

(Kodituwaku, 2011). Jika P_{ij} merupakan piksel j pada channel warna i dan N adalah penjumlahan dari seluruh piksel pada citra, μ adalah nilai *mean* yang dihitung dari persamaan sebelumnya maka standar deviasi yang merupakan moment kedua dalam *color moment* dapat dihitung sebagai berikut:

$$\sigma = \sqrt{\frac{1}{N} \sum_{j=1}^N ((P_{ij} - \mu)^2)} \quad (2.25)$$

c) *Color Moment 3*

Skewness digunakan untuk mengetahui derajat ketidaksimetrisan pada distribusi warna untuk masing-masing channel warna (Herdiyeni, 2012). *Skewness* merupakan pengukuran dimana sebuah distribusi dikatakan simetri apabila seimbang antara kiri dengan kanan pada center point (NIST, 2013).

$$\theta = \frac{\frac{1}{N} \sum_{j=1}^N (P_{ij} - \mu)^3}{\sigma^3} \quad (2.26)$$

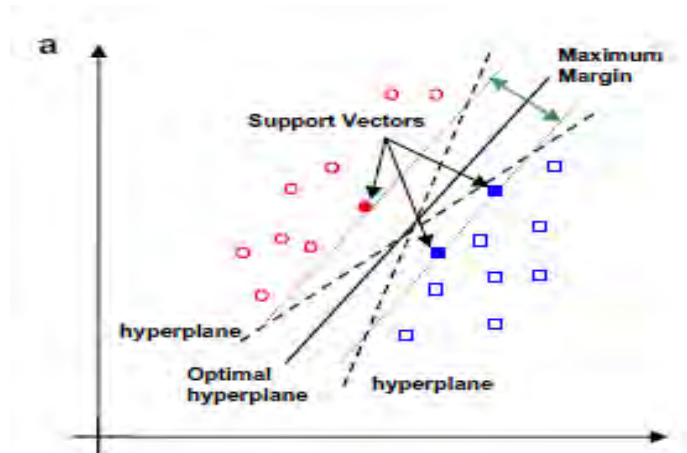
Distribusi dikatakan condong ke kiri apabila memiliki nilai *skewness* berupa bilangan negatif. Sebaliknya, distribusi dikatakan condong ke kanan apabila memiliki nilai *skewness* berupa bilangan positif. Jika distribusi simetris, koefisien *skewness* bernilai nol.

2.8 Support Vector Machine

Tujuan utama SVM adalah menemukan *hyperplane* terbaik yang dapat memisahkan 2 kelas pada input space. *Hyperplane* terbaik didapat dari menghitung margin maksimal dari *hyperplane* dengan fungsi *kernel*. *Kernel trick* membuat data yang telah dipetakan ke dimensi yang lebih tinggi dapat dipisahkan dengan *linear hyperplane*. Akurasi tinggi bisa didapatkan dengan memaksimalkan jarak antara *hyperplane* dan *support vector* (Fitriawan, 2013).

Dalam SVM kita berusaha menemukan fungsi pemisah, dalam hal ini *classifier/ hyperplane* yang optimal untuk memisahkan kelas berbeda. *Hyperplane* terbaik terletak di tengah-tengah antara dua set objek dari dua kelas, dalam hal ini memaksimalkan margin atau jarak antara dua kelas yang berbeda (Elish, 2008). SVM digunakan untuk mengklasifikasikan 2 kelas, apabila terdapat lebih dari 2 kelas maka digunakan strategi salah satunya *one against all* (Shahbudin, 2008). SVM merupakan algoritma klasifikasi dengan langkah sebagai berikut:

a.) Melakukan plot data pada bidang koordinat:



Gambar 2.8 Pemetaan Data pada SVM

Sumber: Elish, 2008

b.) Memaksimalkan margin, berdasarkan persamaan garis pada gambar sebelumnya, dimana w adalah vektor ortogonal dan b adalah bias, sebagai berikut:

$$\begin{aligned}
 X_i \cdot w + b &\geq +1 \text{ for } y_i = +1 \\
 X_i \cdot w + b &\leq -1 \text{ for } y_i = -1 \\
 Y_i (x_i \cdot w + b) - 1 &\geq 0 \qquad (2.27)
 \end{aligned}$$

c.) Optimasi nilai y sebagai *constrained optimization problem* dengan lagrangian

d.) Untuk mengatasi *error* pada klasifikasi, SVM menggunakan *slack variabel* berikut:

$$X_i \cdot w + b \geq +1 - \xi \text{ for } y_i = +1 \qquad (2.28)$$

$$X_i \cdot w + b \leq -1 + \xi \text{ for } y_i = -1 \qquad (2.29)$$

$$Y_i (x_i \cdot w + b) - 1 + \xi \geq 0 \qquad (2.30)$$

e.) Pada beberapa kasus, SVM memisahkan 2 kelas secara non-linier, dengan memetakan data ke ruang yang berdimensi lebih tinggi menggunakan fungsi kernel, misalnya kernel *linear*, *quadratic*, *polynomial* dan *rbf*:

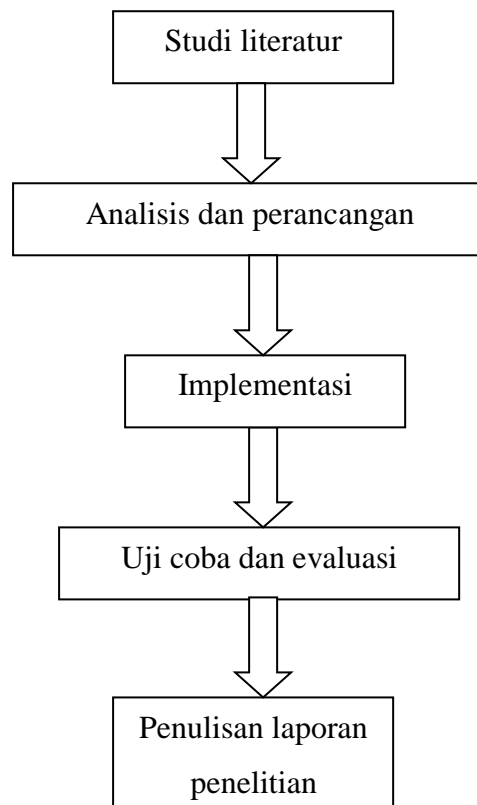
Tabel 2.3 Kernel pada SVM

<i>linear</i>	$K(x_i, x_j) = x_i^T x_j$
<i>quadratic</i>	$K(x_i, x_j) = ((x_i, x_j^T) + 1)^2$
<i>polynomial</i>	$K(x_i, x_j) = ((x_i, x_j^T) + 1)^3$
<i>rbf (radial basis function)</i>	$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j^T\ ^2}{2\sigma^2}\right)$

BAB 3

METODE PENELITIAN

Pada bab ini dijelaskan tahapan metode penelitian yang dilakukan dalam penelitian ini. Secara umum, penelitian dimulai dengan studi literatur, kemudian dilanjutkan dengan analisis, perancangan, dan implementasi serta diakhiri dengan uji coba dan evaluasi hasil. Bagian ini juga menjelaskan tentang data yang digunakan serta skenario uji coba yang dilakukan seperti ditunjukkan dalam Gambar 3.1.



Gambar 3.1 Alur Metode Penelitian

3.1 Studi literatur

Berbagai referensi tentang konsep penyakit karat dan mosaik pada tebu, metode pengenalan pola pada daun berpenyakit, ekstraksi fitur yang digunakan serta metode klasifikasi perlu dikaji untuk menunjang penelitian. Dari hasil studi literatur beberapa konsep tersebut, ditemukan kekurangan dan kelebihan dari

penelitian yang sudah pernah dilakukan sebelumnya. Seperti penyakit karat dan mosaik yang menimbulkan kerugian, identifikasi dilakukan secara manual. Kekurangan identifikasi manual adalah identifikasi bersifat subjektif. Teknologi informasi mempermudah identifikasi penyakit tersebut karena tidak semua petani memiliki pemahaman detail tentang penyakit dan petani tidak perlu menghafal gejala penyakit yang merugikan dan tidak merugikan.

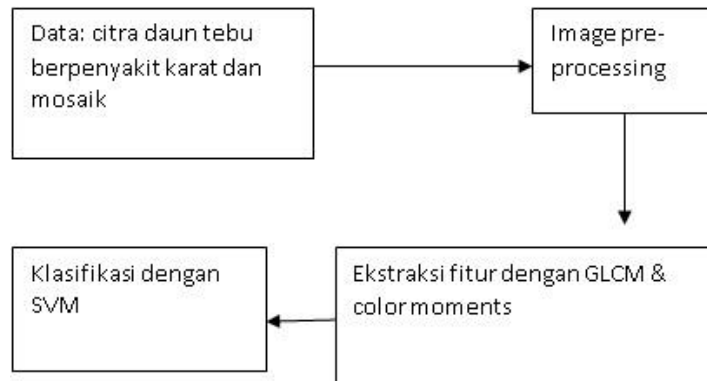
Penelitian yang berkembang mengenai identifikasi penyakit tanaman tebu saat ini berkembang dalam bidang penginderaan jauh, sedangkan identifikasi penyakit tanaman melalui citra digital daun membahas mengenai penyakit tanaman secara umum. Metode identifikasi pada (Camargo, 2009b) menggunakan ekstraksi fitur bentuk, tekstur dan warna. Fitur tersebut kurang sesuai apabila digunakan untuk identifikasi penyakit pada daun tebu karena penyakit karat tidak memiliki pola bentuk yang sama. Oleh karena itu, penelitian ini tidak menggunakan fitur bentuk. Terdapat perbedaan tekstur antara daun normal, berpenyakit karat dan mosaik sehingga perlu adanya ekstraksi fitur tekstur. Penelitian ini memilih *gray level co-occurrence matrix* untuk ekstraksi fitur tekstur. Penggunaan *color moments* untuk warna karena terdapat perbedaan warna pada daun normal dan berpenyakit. *Color moments* merupakan metode ekstraksi fitur yang efektif untuk analisis citra berdasarkan warna karena metode tersebut memiliki dimensi vektor fitur yang paling rendah dan juga kompleksitas komputasional yang paling rendah jika dibandingkan dengan metode lainnya seperti *color histogram*, *color correlogram* dan *color structure descriptor* sehingga penelitian ini memilih *color moments* untuk ekstraksi fitur warna.

Klasifikasi daun tebu berpenyakit dilakukan berdasarkan fitur yang telah diekstraksi pada tahap sebelumnya. Penelitian ini menggunakan metode *support vector machine* (SVM) karena SVM cocok untuk klasifikasi yang datanya sedikit. Selain itu SVM memberikan hasil akurasi yang tinggi untuk analisis penyakit tanaman seperti telah dilakukan pada penelitian sebelumnya mengenai identifikasi penyakit tanaman secara umum. Pemilihan fitur GLCM dan *color moments* dengan metode klasifikasi SVM diharapkan sesuai untuk identifikasi penyakit pada daun tebu.

3.2 Analisis dan Perancangan

Analisis dilakukan berkaitan dengan penyakit tebu yaitu karat dan mosaik serta gejala yang tampak pada daun. Gejala penyakit karat adalah bercak kecil berwarna kuning, kemudian menjadi semakin besar dan dapat menjadi berwarna coklat. Gejala paling menonjol dari penyakit mosaik adalah perbedaan warna dari warna daun yang hijau (normal) menjadi adanya garis atau area klorotik berwarna hijau pucat sampai dengan kuning tua.

Langkah selanjutnya adalah merancang langkah- langkah penelitian untuk membangun metode pengenalan pola penyakit tebu ditinjau dari citra digital daun. Gambar berikut menunjukkan perancangan langkah-langkah penelitian:



Gambar 3.2 Langkah Penelitian

Perancangan langkah-langkah penelitian dalam penelitian ini sebagai berikut:

a) Pengumpulan data

Langkah pertama adalah pengumpulan data, data citra daun tebu baik normal, berpenyakit karat maupun berpenyakit mosaik difoto dengan kamera digital. Hasil tahap ini adalah citra digital daun tebu.

b) Pre-processing

Proses selanjutnya adalah pre-processing citra. Tujuan proses ini adalah menyiapkan data untuk dapat diproses dalam proses selanjutnya yaitu ekstraksi fitur. Hasil dari pre-processing citra adalah daerah yang representative dalam 2 bentuk, yaitu hasil transformasi RGB menjadi citra keabuan dan transformasi RGB menjadi citra dalam ruang warna CIELAB. Proses transformasi RGB ke citra gray dan RGB ke ruang warna LAB dijelaskan dalam bab tinjauan pustaka.

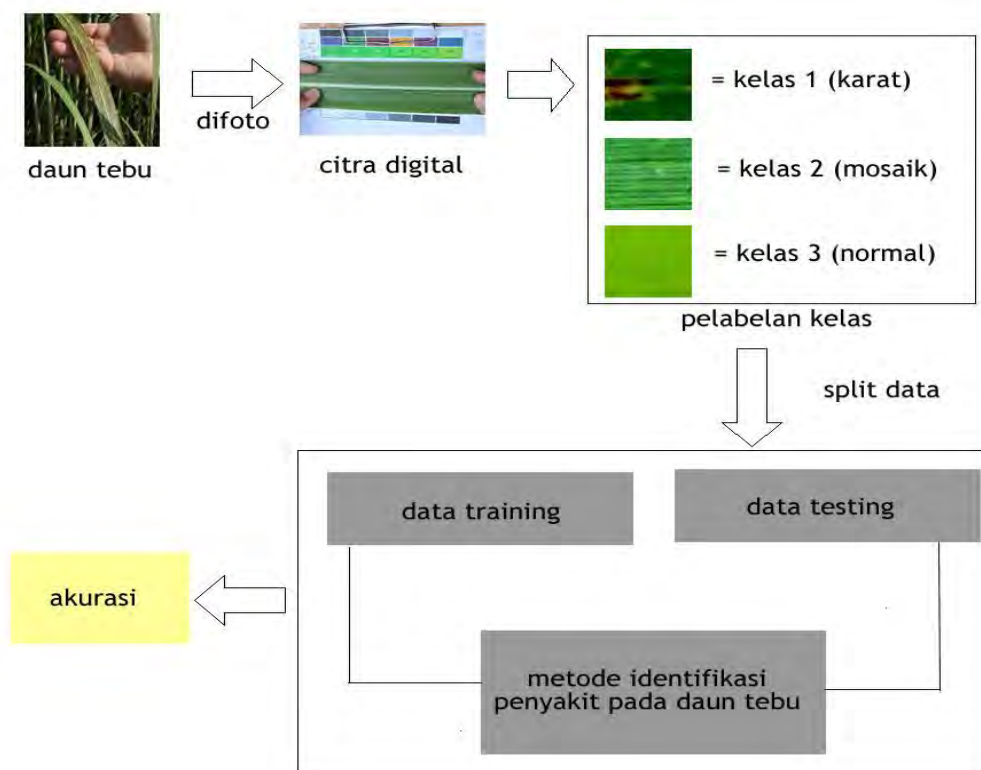
c) Ekstraksi fitur

Ekstraksi fitur dilakukan dengan GLCM untuk ekstraksi fitur tekstur dan *color moments* untuk ekstraksi fitur warna. Penjelasan mengenai GLCM dan *color moments* terdapat pada bab tinjauan pustaka.

d) Klasifikasi

Klasifikasi dilakukan berdasarkan ekstraksi fitur yang dilakukan sebelumnya. Metode yang digunakan dalam penelitian ini adalah metode klasifikasi dengan SVM. Penjelasan mengenai SVM terdapat pada bab tinjauan pustaka.

Setelah merancang langkah penelitian, tahap selanjutnya adalah perancangan sistem yang terbagi menjadi dua, yaitu arsitektur sistem dan metode untuk identifikasi penyakit pada daun tebu. Arsitektur sistem dijelaskan dalam Gambar 3.3.



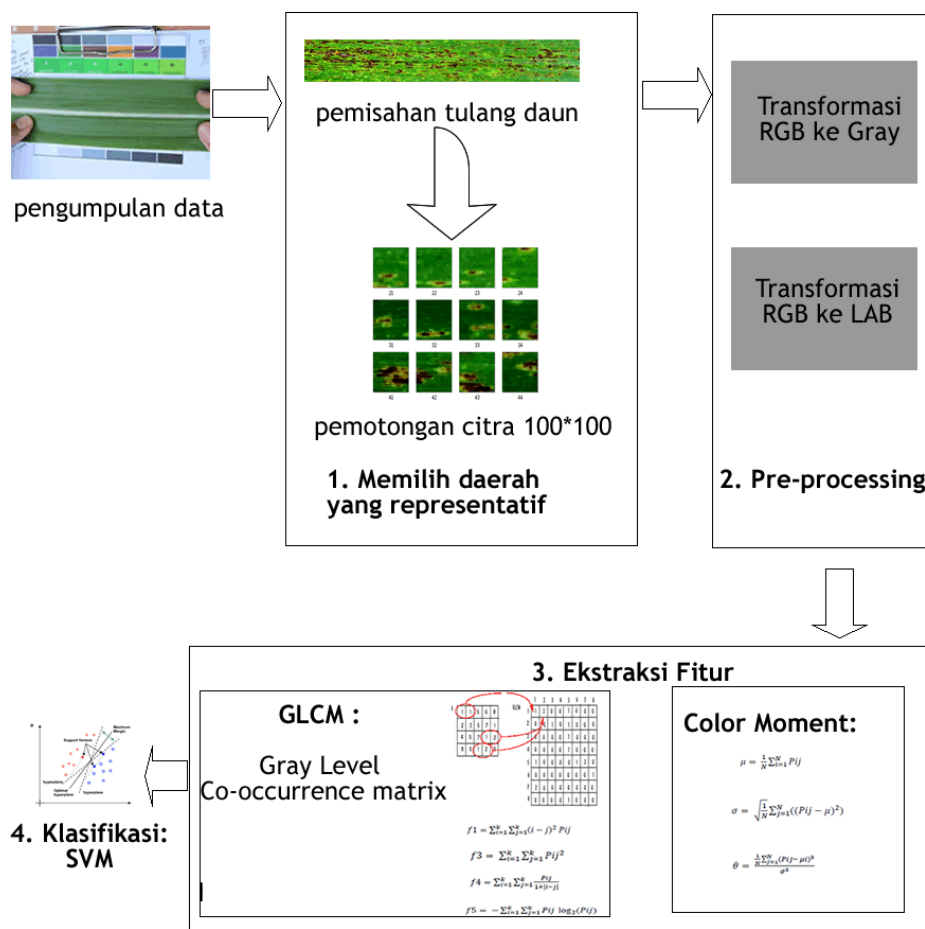
Gambar 3.3 Arsitektur Sistem

Daun tebu difoto di atas kertas menggunakan kamera digital. Spesifikasi minimum yang sebaiknya dimiliki oleh kamera digital adalah 5 Megapiksel agar

dapat mengambil citra dengan kualitas yang baik. Citra digital daun tebu kemudian diberikan label sesuai kelas, yaitu kelas 1 untuk tebu dengan penyakit karat, kelas 2 untuk tebu dengan penyakit mosaik dan kelas 3 untuk tebu normal.

Proses selanjutnya adalah melakukan split data menjadi data training dan data testing. Data training digunakan untuk pembelajaran dalam metode identifikasi penyakit pada daun tebu. Setelah itu, metode identifikasi penyakit daun tebu yang telah terbentuk dilakukan uji coba pada data testing. Hasil uji coba berupa akurasi yang menunjukkan seberapa akurat sistem yang terbentuk dari metode identifikasi penyakit daun tebu.

Metode untuk identifikasi penyakit pada daun tebu dijelaskan pada Gambar 3.4. Langkah pertama adalah pengumpulan data, data citra daun tebu baik normal, berpenyakit karat maupun berpenyakit mosaik difoto dengan kamera digital. Hasil tahap ini adalah citra digital daun tebu.



Gambar 3.4 Metode Identifikasi Penyakit pada Daun Tebu

Proses selanjutnya adalah *pre-processing* citra. Tujuan proses ini adalah menyiapkan data untuk dapat diproses dalam proses selanjutnya yaitu ekstraksi fitur. Hasil dari *pre-processing* citra adalah daerah yang representatif dalam 2 bentuk, yaitu hasil transformasi RGB menjadi citra keabuan dan transformasi RGB menjadi citra dalam ruang warna CIELAB.

Proses selanjutnya adalah ekstraksi fitur tekstur dengan *GLCM* dan ekstraksi fitur warna dengan *color moments*. Hasil tahap ekstraksi fitur ini adalah matriks dari masing-masing fitur yang diekstraksi. Tahap terakhir adalah klasifikasi. Klasifikasi daun tebu berpenyakit dilakukan menggunakan metode *support vector machine* (SVM).

3.3 Implementasi

Pada tahap ini, analisis dan desain yang telah dibuat, diimplementasikan pada perangkat lunak MATLAB R2011b. Spesifikasi perangkat keras yang digunakan adalah laptop Acer Aspire 4720, dengan spesifikasi prosesor intel Core 2 Duo 2.2 GHz, RAM 1024 MB, dan Hard disk 160 GB.

Citra yang digunakan untuk training adalah 300 citra, dengan 100 citra untuk masing-masing kelas. Pengujian menggunakan 300 citra, dengan 100 citra untuk masing-masing kelas. Kelas yang dimaksud adalah kelas normal, mosaik dan karat. Ukuran citra yang digunakan adalah 100*100 piksel.

3.4 Uji Coba dan Evaluasi

Pengujian dilakukan dengan menganalisis akurasi hasil dari hasil klasifikasi dengan strategi pengujian yang dilakukan sebagai berikut:

- a) Mencoba 1 per 1 fitur kemudian dianalisis akurasinya
- b) Per grup (misal: grup tekstur: 5 fitur)
- c) Seluruh grup-1 fitur
- d) Seluruh fitur

Strategi tersebut dilakukan untuk mengetahui fitur yang kemunculannya menyebabkan perubahan dalam hasil klasifikasi. Evaluasi hasil uji coba dilakukan dengan menganalisis hasil akurasi yang didapatkan dari paduan fitur yang diuji dalam tahap uji coba.

3.5 Penulisan Laporan Penelitian

Setiap kegiatan yang dilakukan dalam penelitian ini didokumentasikan. Laporan penelitian ditulis berdasarkan ketentuan yang berlaku.

BAB 4

HASIL DAN PEMBAHASAN

Pada bab ini dijelaskan hasil perancangan sistem, skenario pengujian beserta hasil pengujian dan analisis hasil uji yang diperoleh. Pengujian dilakukan untuk mengetahui pengaruh penghapusan fitur bentuk, pemilihan fitur tekstur dengan GLCM dan pemilihan fitur warna dengan *color moments*. Pada bagian akhir bab ini membahas pengaruh kombinasi fitur tekstur dan warna untuk identifikasi penyakit pada daun tebu.

1.1 Hasil Perancangan Sistem

Perancangan sistem yang telah dibuat pada bab metode penelitian berupa langkah-langkah penelitian menghasilkan keluaran sebagai berikut:

1.1.1. Pengumpulan data

Varietas tebu yang digunakan dalam penelitian ini adalah BL dan PSJK. Waktu pengambilan *sample* tebu adalah pada akhir fase perpanjangan batang. Pada penelitian ini, perkebunan tebu yang diteliti berada di Jawa Timur, lebih tepatnya di Malang, yaitu pada perkebunan tebu milik PG. Kebon Agung.

Pengumpulan data dilakukan perkebunan tebu di Malang dan sekitarnya pada tanggal 26-27 Agustus 2013 dan 2 September 2013, dengan detail lokasi perkebunan tebu ditunjukkan pada Tabel 4.1.

Tabel 4.1 Lokasi Pengambilan Data

Dusun	Desa	Kecamatan
Gondowangi	Gondowangi	Wagir
Wiloso	Gondowangi	Wagir
Binangun	Genengan	Pakisaji
Pakisaji	Pakisaji	Pakisaji
Babadan	Babadan	Ngajum
Kesamben	Kesamben	Ngajum
Patuksari	Plaosan	Wonosari

Kromengan	Kromengan	Kromengan
Tegaron	Panggungrejo	Kepanjen
Tegaron	Panggungrejo	Kepanjen
Terong Dowo	Tirtomoyo	Pakis
Tamanharjo	Tamanharjo	Singosari
Krajan	Dengkol	Singosari
Tomporejo	Dengkol	Singosari

Langkah-langkah pengambilan data citra dilakukan sebagai berikut:


- a) Mencari tebu normal, berpenyakit karat, dan berpenyakit mosaik.
- b) Memfoto daun di atas kertas. Setiap daun difoto minimal 1 kali dengan kondisi pencahayaan cerah atau redup (d disesuaikan kondisi cuaca pada saat pengambilan data) dan jarak daun dari kamera 15 cm. Citra diambil menggunakan 3 kamera berbeda dengan spesifikasi seperti tertera pada Tabel 4.2.

Tabel 4.2 Jenis dan Spesifikasi Kamera

NAMA KAMERA	SPESIFIKASI
Canon EOS 450D	12.2 MP CMOS sensor 3.5fps <i>9-point wide-area AF</i> <i>EOS Integrated Cleaning System</i> <i>3.0" LCD Live View mode</i> <i>DIGIC III processor</i>
Canon EOS 600D	18-megapixel CMOS sensor <i>Scene Intelligent Auto mode</i> <i>3.7fps continuous shooting</i> <i>Wide-area 9-point AF</i> 1,040k-dot <i>vari-angle 7.7cm (3.0") screen</i>
Lenovo P770	5 MP, autofocus, LED flash dengan <i>Geo-tagging</i>
Samsung Galaxy Ace 2	CMOS, 5.0 MP Megapixels Camera Resolution(Rear) Flash-LED Flash, Auto Focus

Hasil data daun yang diperoleh dari observasi lapangan seperti terdapat pada Gambar 4.1 sampai dengan 4.3. Langkah selanjutnya adalah pelabelan kelas. Kriteria penentuan kelas daun yaitu normal, berpenyakit karat dan berpenyakit mosaik didapatkan dari pengetahuan pakar.

Pada saat observasi lapangan, pakar memberikan kriteria bahwa jika daun berwarna hijau tanpa ada noda maka daun tersebut normal. Jika ada noda berwarna kuning sampai dengan coklat pada daun berwarna hijau, maka daun tersebut berpenyakit karat. Jika daun berwarna hijau dengan noda berupa garis-garis berwarna hijau pucat, maka daun tersebut berpenyakit mosaik.



Gambar 4.1 Daun Tebu Normal




Gambar 4.2 Penyakit Karat



Gambar 4.3 Penyakit Mosaik


Proses selanjutnya dilakukan dengan memilih daerah yang representatif pada citra daun untuk digunakan dalam penelitian. Caranya adalah memisahkan tulang daun dari daun secara keseluruhan sehingga didapatkan citra daun bagian atas dan bawah. Proses ini dilakukan secara manual. Citra hasil pemisahan tulang daun dapat dilihat pada gambar berikut:



Gambar 4.4 Citra Hasil Pemisahan Tulang Daun

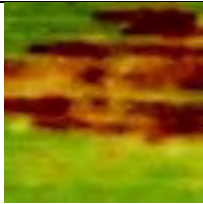
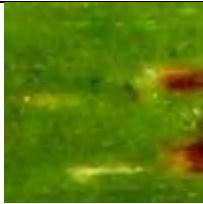
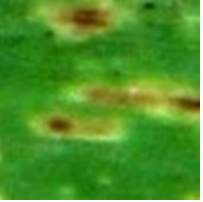
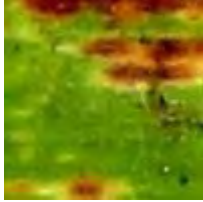
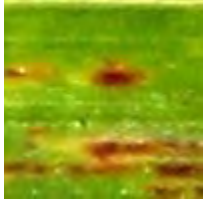

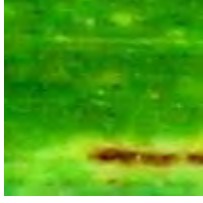

Citra daun tersebut kemudian dipotong berbentuk persegi dengan ukuran 100*100 piksel kemudian memilih daerah yang merepresentasikan kelas. Hasil pemotongan citra pada masing-masing kelas, yaitu normal, karat dan mosaik dikelompokkan dalam 1 folder. Gambar 4.5 adalah hasil pemotongan citra untuk kelas karat.

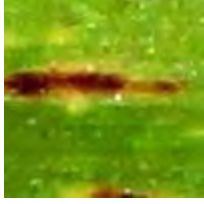
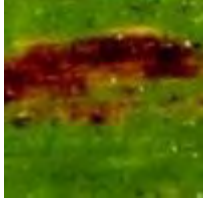
Hasil dari tahap pengumpulan data adalah data citra daun tebu yang berjumlah 600 citra. Citra yang digunakan untuk training adalah 300 citra, dengan 100 citra untuk masing-masing kelas. Pengujian menggunakan 300 citra, dengan 100 citra untuk masing-masing kelas. Tabel 4.5 menunjukkan 5 contoh citra untuk masing-masing kelas.



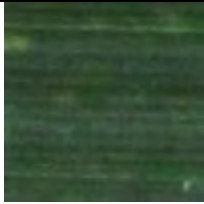
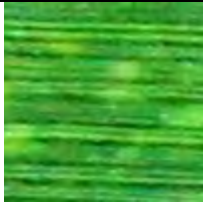



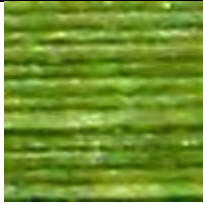




Gambar 4.5 Hasil Pemotongan Citra

Tabel 4.3 Citra Karat

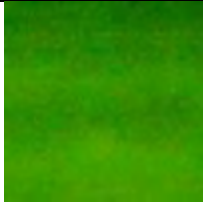





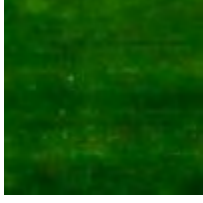



Citra	Kelas	Citra	Kelas
	1		1
	1		1
	1		1
	1		1

	1		1
---	---	---	---

Tabel 4.4 Citra Mosaik

Citra	Kelas	Citra	Kelas
	2		2
	2		2
	2		2
	2		2
	2		2

Tabel 4.5 Citra Normal

Citra	Kelas	Citra	Kelas
	3		3
	3		3
	3		3
	3		3
	3		3

1.1.2. *Pre-processing Citra*

Proses selanjutnya adalah pre-processing citra. Tujuan proses ini adalah menyiapkan data untuk dapat diproses dalam proses selanjutnya yaitu ekstraksi fitur. Pre-processing citra terdiri dari transformasi RGB ke citra keabuan dan transformasi citra RGB ke LAB. Data yang didapatkan dari proses pengumpulan data berformat RGB. Data tersebut kemudian diubah menjadi citra keabuan untuk dapat diolah dalam ekstraksi fitur GLCM.

Penelitian ini menggunakan metode *luminosity* untuk transformasi citra RGB menjadi citra keabuan karena metode ini lebih dekat ke persepsi penglihatan manusia. Metode transformasi *luminosity* menghitung nilai setiap elemen warna,

yaitu *Red*, *Green*, dan *Blue* dengan menambahkan bobot sesuai persepsi penglihatan manusia. Penglihatan manusia lebih sensitif terhadap warna hijau oleh karena itu elemen warna *G* memiliki bobot yang paling tinggi dari elemen warna lainnya.

$$Luminosity = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (2.5)$$

Tahap *pre-processing* kedua adalah transformasi citra dalam format RGB ke LAB. Elemen warna RGB dipisahkan sesuai *channel* warna (R, G, B) dan diubah ke dalam ruang warna LAB untuk dapat diproses dalam ekstraksi fitur *color moments*.

Transformasi ruang warna RGB ke CIELAB memiliki dua tahapan yang dijelaskan oleh rumus (2.6) untuk transformasi ruang warna RGB ke CIE XYZ, dan rumus (2.7), (2.8), (2.9) untuk transformasi dari XYZ ke CIELAB.

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0,412453 & 0,357580 & 0,180423 \\ 0,212671 & 0,715160 & 0,072169 \\ 0,019334 & 0,119193 & 0,950227 \end{bmatrix} \times \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.6)$$

Transformasi dari XYZ menjadi LAB mengikuti persamaan seperti berikut:

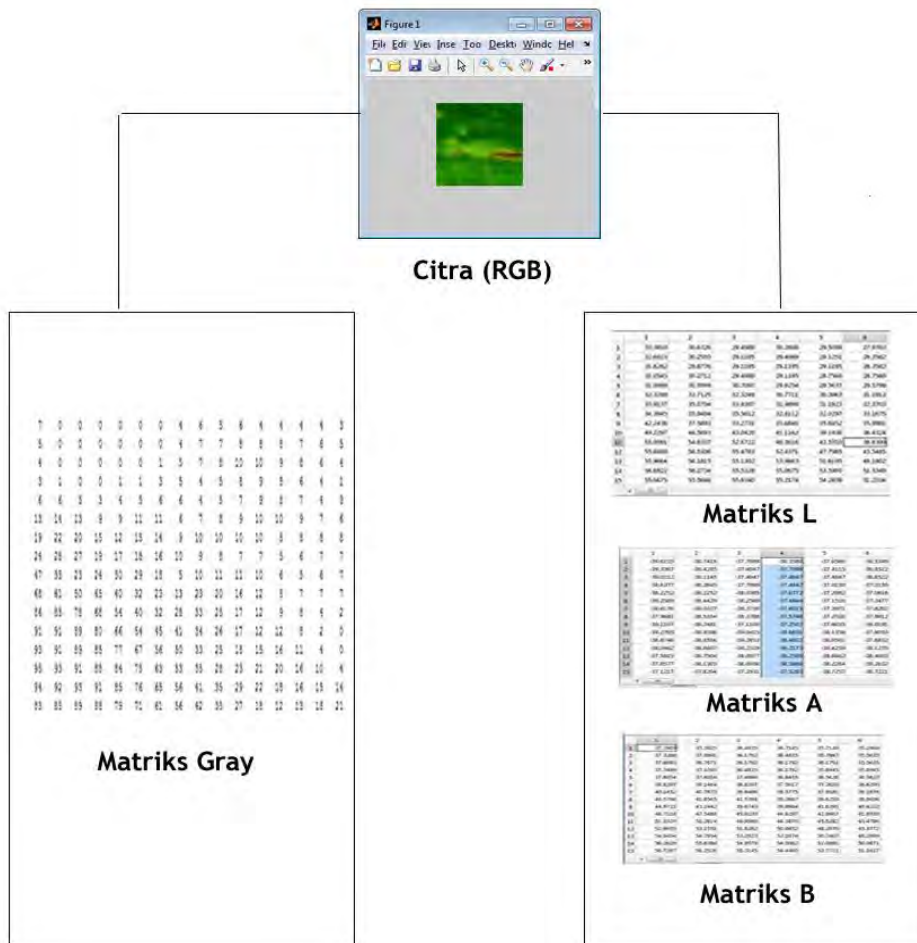
$$L = 116 \times f\left(\frac{Y}{Y_w}\right) - 16 \quad (2.7)$$

$$a^* = 500 \left[f\left(\frac{X}{X_w}\right) - f\left(\frac{Y}{Y_w}\right) \right] \quad (2.8)$$

$$b^* = 200 \left[f\left(\frac{Y}{Y_w}\right) - f\left(\frac{Z}{Z_w}\right) \right], \quad (2.9)$$

dimana $f(t) = t^{1/3}$ untuk $t > 0.008856$ dan $f(t) = 7.787 \times t + 16/116$ untuk $t \leq 0.008856$. XYZ merepresentasikan referensi standar untuk nilai tristimulus warna putih berdasarkan CIE55 yang didefinisikan oleh $x = 0.3324$ dan $y = 0.3474$.

Hasil dari pre-processing citra adalah matriks dalam 2 bentuk, yaitu hasil transformasi RGB menjadi citra keabuan dan transformasi RGB menjadi citra dalam ruang warna CIELAB seperti terdapat dalam Gambar 4.6




Gambar 4.6 Hasil *Pre-processing* Citra

1.1.3. Ekstraksi Fitur

Ekstraksi fitur dilakukan dengan GLCM untuk ekstraksi fitur tekstur dan *color moments* untuk ekstraksi fitur warna. *Gray Level Co-occurrence Matrix* (GLCM) dilakukan pada matriks keabuan yang telah didapatkan dari tahap *pre-processing* dengan membentuk matriks *co-occurrence*. Pembentukan matriks *co-occurrence* menggunakan fungsi “*graycomatrix*” yang ada pada Matlab.

Jika G_{ij} adalah jumlah berapa kali piksel dengan tingkat keabuan i terjadi berdampingan dengan tingkat keabuan j dan n adalah jumlah pasangan piksel maka P_{ij} yang merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j dapat dihitung dengan membagi G_{ij} dengan n .



Gambar 4.7 Ilustrasi Matriks Co-occurrence

Penghitungan statistik GLCM yang digunakan dalam penelitian ini menggunakan P_{ij} sebagai dasar penghitungan. Berdasarkan teori GLCM pada bab dasar teori, untuk 1 sampai k jumlah piksel dalam sebuah citra, jika P_{ij} merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j , penghitungan statistik GLCM dapat dijelaskan sebagai berikut:

Tabel 4. 6 Penghitungan Statistik GLCM

Fitur GLCM	Penghitungan
Contrast	$f1 = \sum_{i=1}^k \sum_{j=1}^k (i - j)^2 P_{ij}$
Energy	$f2 = \sum_{i=1}^k \sum_{j=1}^k P_{ij}^2$
Homogeneity	$f3 = \sum_{i=1}^k \sum_{j=1}^k \frac{P_{ij}}{1 + i - j }$
Entropy	$f4 = - \sum_{i=1}^k \sum_{j=1}^k P_{ij} \log_2(P_{ij})$
Variance	$f5 = \sum_i \sum_j (i - \mu)^2 P_{ij}$
Correlation	$f6 = \frac{\sum_i \sum_j P_{ij} - \mu_x \mu_y}{\sigma_x \sigma_y}$

sum average	$f7 = \sum_{i=2}^{2Np} iPx + y (i)$
sum entropy	$f8 = - \sum_{i=2}^{2Np} Px + y(i) \log\{Px + y(i)\}$
sum variance	$f9 = \sum_{i=2}^{2Np} (i - f6)^2 Px + y (i)$
difference variance	$f10 = \text{variance } (Px - y)$
difference entropy	$f11 = - \sum_{i=2}^{2Np} Px - y(i) \log\{Px - y(i)\}$
information measures of correlation 1	$f12 = \frac{HXY - HXY1}{\max\{HX, HY\}}$
information measures of correlation 2	$f13 = \sqrt{(1 - \exp[-2.0(HXY2 - HXY)])}$
maximum correlation coefficient	$f14 = 2nd \text{ eigen value } \sum_k \frac{P(i, k)P(j, k)}{Px(i)Py(k)}$

Pemilihan fitur GLCM didasarkan dari analisis hasil pengujian akurasi untuk memilih fitur terbaik yang cocok untuk identifikasi penyakit pada daun tebu. Berikut adalah peringkat akurasi tertinggi ke terendah dari fitur GLCM:

Tabel 4. 7 Pengujian Akurasi per Fitur GLCM

Fitur GLCM	Akurasi
information measures of correlation 2	89, 70 %
correlation	81 %
information measures of correlation 1	79%
energy	78,67%
sum entropy	76,67%
homogeneity	63,67%
contrast	63,67%
difference variance	63,67%
difference entropy	63,33%
entropy	53,33%
sum variance	45,67%
sum average	35,33%
sum squares	34,33%
maximum correlation coefficient	33,33%

Dari tabel tersebut diketahui bahwa dari 14 fitur GLCM, correlation beserta turunannya yaitu information measures of correlation 1 dan 2 menempati 3 tempat teratas untuk pengujian akurasi, sehingga untuk pemilihan fitur GLCM yang pertama dipilih correlation. Hasil pengujian akurasi teratas kemudian diikuti energy dan sum entropy, energy dan entropy sama-sama merepresentasikan keseragaman pola tekstur ditinjau dari rumusnya. Entropy akan bernilai tinggi saat teksturnya tidak seragam, sedangkan energy bernilai rendah.

Energy lebih dipilih dari entropy karena nilai energy sudah berada dalam range yang dinormalisasi. Oleh karena itu, pemilihan fitur GLCM kedua adalah energy. Peringkat selanjutnya adalah homogeneity dan contrast, keduanya sama-sama merepresentasikan konsentrasi GLCM pada diagonal sehingga nilai homogeneity tinggi menunjukkan perbedaan nilai gray yang kecil pada pasangan piksel, sedangkan nilai contrast rendah. Oleh karena itu, pemilihan fitur GLCM ketiga adalah homogeneity. Pemilihan fitur GLCM keempat adalah variance karena variance merepresentasikan heterogenitas pada citra, nilai variance yang tinggi menunjukkan nilai gray yang berbeda dengan nilai rata-rata GLCM. Selain 4 fitur GLCM yang dipilih, fitur lainnya adalah turunan dari 4 fitur GLCM terpilih.

Hasil ekstraksi fitur GLCM adalah matriks yang memiliki nilai sesuai analisis statistik GLCM dan *direction* sebagai berikut:

Tabel 4.8 Analisis Statistik GLCM dan *Direction*

Analisis statistik GLCM	<i>Direction</i> (x^θ)
Correlation	0
	45
	90
	135
Energy	0
	45
	90
	135
Homogeneity	0
	45
	90
	135
Variance	0
	45
	90
	135

Pada pengujian seluruh fitur dikurangi *correlation*, *energy*, *homogeneity* dan *variance* menunjukkan penurunan akurasi dari fitur keseluruhan yang diajukan dalam penelitian ini. Hal ini menunjukkan bahwa 4 fitur GLCM tersebut merupakan fitur yang berpengaruh dalam identifikasi penyakit karena ketidakhadirannya membawa penurunan hasil akurasi.

Tabel 4. 9 Akurasi Seluruh Fitur Tekstur

Jenis Pengujian	Fitur	Akurasi
Seluruh Fitur		97 %
Seluruh -1 Fitur	Seluruh fitur tanpa <i>correlation</i>	94,33 %
	Seluruh fitur tanpa <i>energy</i>	95,67 %
	Seluruh fitur tanpa <i>homogeneity</i>	95,67 %
	Seluruh fitur tanpa <i>variance</i>	96 %

Pada tahap ekstraksi fitur color moments, matriks yang digunakan adalah matriks L,A,B dari hasil transformasi citra RGB ke CIELAB yang telah dilakukan pada tahap *pre-processing*. Pada proses ekstraksi fitur, *color moment* menggunakan 3 *moment* penting sebagai berikut:

Berdasarkan teori *color moments* pada bab dasar teori, jika P_{ij} merupakan piksel j pada channel warna i dan N adalah penjumlahan dari seluruh piksel pada citra, maka *color moments* 1,2 dan 3 dapat dihitung sebagai berikut:

Tabel 4. 10 Penghitungan Color Moment

Color Moments	Penghitungan
Color Moment 1	$\mu = \frac{1}{N} \sum_{i=1}^N P_{ij}$
Color Moment 2	$\sigma = \sqrt{\frac{1}{N} \sum_{j=1}^N ((P_{ij} - \mu)^2)}$
Color Moment 3	$\theta = \frac{\frac{1}{N} \sum_{j=1}^N (P_{ij} - \mu)^3}{\sigma^3}$

Pemilihan fitur *color moments* didasarkan pada hasil akurasi per fitur *color moments* berikut:

Tabel 4. 11 Pengujian Akurasi Per Fitur *Color Moments*

<i>Color moments</i>	Akurasi
<i>color moment 1</i>	52,33 %
<i>color moment 2</i>	93,67 %
<i>color moment 3</i>	67,33 %

Dari tabel tersebut dapat diketahui bahwa *color moment 2* menghasilkan akurasi tertinggi. Untuk memilih fitur *color moment* maka dilakukan pengujian kelompok fitur yang berisi *color moment 1,2* dan *3*.

Analisis dari akurasi tersebut kembali ke konsep *color moment* yang menyaakan probabilitas distribusi warna dapat dikenali dari *moment* warna, misalnya distribusi normal yang dapat dianalisis dari *color moment 1* dan *2*. Sedangkan *color moment 3* digunakan untuk mengetahui derajat ketidaksimetrisan distribusi warna. Sehingga dapat disimpulkan bahwa ketiganya merupakan kesatuan untuk analisis fitur warna. Untuk mengetahui pengaruh masing-masing moment maka dilakukan pengujian seluruh kelompok fitur dikurangi 1 fitur berikut:

Tabel 4. 12 Pengujian Akurasi Kelompok dan Seluruh Fitur

Jenis Pengujian	Fitur	Akurasi
Kelompok Fitur	Tekstur	90,33 %
	Warna	96 %
Seluruh Fitur		97 %
Seluruh -1 Fitur	Seluruh fitur tanpa <i>color moment 1</i>	96,33 %
	Seluruh fitur tanpa <i>color moment 2</i>	91,67 %
	Seluruh fitur tanpa <i>color moment 3</i>	97 %

Dari tabel di atas diketahui bahwa pengurangan fitur *color moment 1* dan *2* menurunkan akurasi sehingga *color moment 1* dan *2* dipilih untuk fitur warna penelitian ini dengan menyertakan *color moment 3* karena fitur *color moment 3* juga tidak memperburuk ataupun memperbaiki akurasi keseluruhan fitur.

Hasil ekstraksi fitur *color moment* adalah matriks yang memiliki nilai sesuai elemen warna dan *color moment* yang dianalisis sebagai berikut:

Tabel 4.13 Elemen warna dan *color moment*

<i>Color Moment</i>	Elemen Warna
<i>Color Moment 1</i>	L
	A
	B
<i>Color Moment 2</i>	L
	A
	B
<i>Color Moment 3</i>	L
	A
	B

1.1.4. Klasifikasi

Klasifikasi dilakukan berdasarkan matriks hasil ekstraksi fitur yang dilakukan pada tahap sebelumnya. Metode klasifikasi yang digunakan dalam penelitian ini adalah metode klasifikasi dengan SVM. SVM merupakan algoritma klasifikasi dengan konsep memetakan data sebagai *support vector* dan membentuk *hyperplane* untuk memisahkan 2 kelas data. *Hyperplane* terbaik didapatkan dengan memaksimalkan margin, yaitu jarak antara 2 *support vector* yang berbeda kelas seperti diilustrasikan pada gambar berikut:

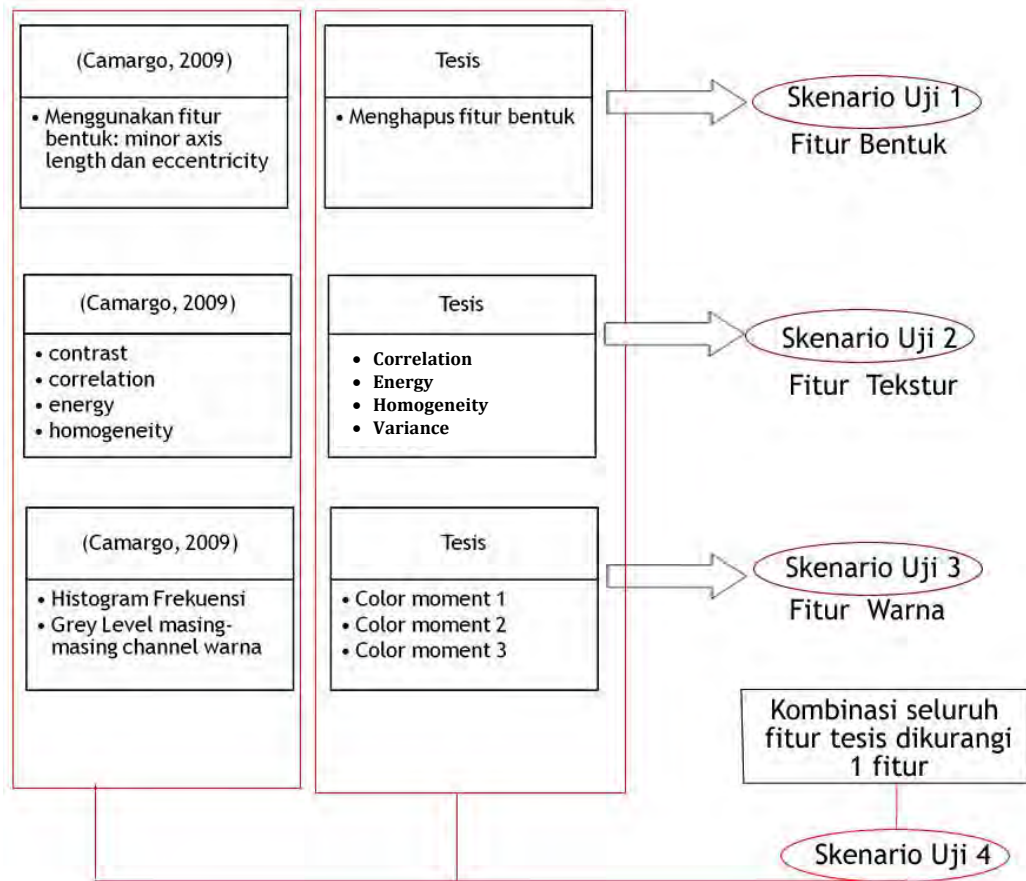
Kernel SVM yang digunakan dalam penelitian ini adalah kernel linear. SVM untuk klasifikasi 2 kelas menggunakan fungsi “*svmclassify*” yang ada di Matlab. Sedangkan klasifikasi multi kelas (kelas karat, mosaik dan normal) menggunakan fungsi *multiclass svm* yang diunduh dari mathworks.

1.2 Tahapan Pengujian Sistem

Pengujian akurasi digunakan untuk mengetahui performa sistem dalam mengklasifikasikan tebu normal, berpenyakit mosaik, dan berpenyakit karat berdasarkan paduan fitur dan teknik klasifikasi yang diusulkan dalam metode penelitian.

Skenario uji dilakukan untuk mengetahui pengaruh kombinasi fitur terhadap hasil klasifikasi. Skenario dilakukan untuk mengetahui pengaruh penghapusan fitur bentuk (skenario 1), pemilihan fitur tekstur dengan GLCM (skenario 2) dan pemilihan fitur warna dengan color moments (skenario 3) serta pengaruh kombinasi fitur tekstur dan warna untuk identifikasi penyakit pada daun

tebu (skenario 4) sehingga ditemukan paduan fitur yang akurat untuk identifikasi penyakit tebu. Alur skenario uji dijelaskan dalam gambar berikut:



Gambar 4. 8 Alur Skenario Uji

Tabel 4. 14 Skenario Uji

Skenario Uji	Tujuan
1	Pengaruh penghapusan fitur bentuk dengan <i>minor axis length</i> dan <i>eccentricity</i>
2	Pengaruh pemilihan fitur tekstur dengan GLCM
3	Pengaruh pemilihan fitur warna dengan color moments
4	Pengaruh kombinasi fitur warna dan tekstur

Pengujian dilakukan dengan menganalisis akurasi hasil dari hasil klasifikasi dengan penghitungan sebagai berikut:

$$Akurasi = \frac{T1+T2+T3}{T1+F1+T2+F2+T3+F3} \quad (4.1)$$

Dimana $T1$ adalah prediksi benar untuk kelas 1, $T2$ adalah prediksi benar untuk kelas 2, dan $T3$ adalah prediksi benar untuk kelas 3. Sedangkan $F1$ adalah prediksi salah untuk kelas 1, $F2$ adalah prediksi salah untuk kelas 2 dan $F3$ adalah prediksi salah untuk kelas 3.

Rumus pengujian akurasi dapat dipersingkat dengan menyatukan $T1$, $T2$, dan $T3$ sebagai data yang diprediksi dengan benar dan $T1$, $F1$, $T2$, $F2$, $T3$, $F3$ sebagai jumlah keseluruhan data.

$$Akurasi = \frac{\text{Jumlah data yang diprediksi dengan benar}}{\text{Jumlah keseluruhan data}} \quad (4.2)$$

1.3 Skenario Uji 1

Skenario uji 1 dilakukan untuk mengetahui pengaruh penghapusan fitur bentuk. Pada penelitian sebelumnya mengenai identifikasi penyakit tanaman secara umum (Camargo, 2009b) merekomendasikan fitur bentuk (*minor axis length* dan *eccentricity*), tekstur (*contrast*, *correlation*, *energy*, *homogeneity*) dan warna (histogram frekuensi dan *grey level* untuk masing-masing *channel* warna).

Pada penelitian ini mengusulkan penghapusan fitur bentuk, menggunakan fitur tekstur dengan *correlation*, *energy*, *homogeneity* dan *variance* serta fitur warna dengan *color moment* 1, 2 dan 3.

Tabel 4.15 Fitur Skenario Uji 1

Fitur	Camargo, 2009	Tesis
Bentuk	Menggunakan <i>minor axis length</i> dan <i>eccentricity</i>	Menghapus fitur bentuk

Skenario uji diujikan pada data yang sama, yaitu 300 data daun tebu dengan 100 normal, 100 memiliki penyakit karat dan 100 memiliki penyakit mosaik. Pada skenario uji 1 akan diteliti hasil pengujian akurasi untuk paduan fitur yang diusulkan pada penelitian sebelumnya kemudian membandingkannya dengan fitur yang sama namun fitur bentuk dihapus. Selanjutnya 2 hasil pengujian tersebut dibandingkan dengan hasil akurasi fitur yang diusulkan dalam penelitian ini.

1.3.1. Hasil Uji Skenario 1

Hasil pengujian akurasi yang dilakukan sesuai skenario 1 untuk mengetahui pengaruh penghapusan fitur bentuk dijelaskan dalam tabel berikut:

Tabel 4.16 Akurasi Skenario Uji 1

Fitur	Akurasi
Camargo, 2009	85,67 %
Camargo, 2009 - bentuk	86,33 %
Tesis	97 %

Hasil uji skenario 1 menunjukkan bahwa ada pengaruh penghapusan fitur bentuk, yaitu saat menggunakan fitur bentuk pada Camargo akurasi yang didapatkan 85,67% sedangkan saat fitur bentuk dihapus akurasi semakin baik yaitu naik menjadi 86,33 %. Hasil ini juga dibandingkan dengan penelitian ini, yaitu akurasi 97 %.

1.3.2. Analisis Hasil Uji Skenario 1

Saat menggunakan fitur bentuk pada Camargo akurasi yang didapatkan 85,67% sedangkan saat fitur bentuk dihapus akurasi semakin baik yaitu naik menjadi 86,33 %. Hal ini disebabkan penelitian Camargo merekomendasikan identifikasi pola penyakit tanaman secara umum, apabila diuji coba pada tanaman yang spesifik seperti tebu maka fitur yang diusulkan kurang cocok untuk identifikasi penyakit pada tanaman tebu, hal tersebut karena pola penyakit karat pada tebu memiliki pola bentuk yang tidak beraturan.

Hasil pengujian akurasi Camargo yang telah dihapus fitur bentuknya dibandingkan dengan hasil pengujian akurasi penelitian ini yang menghapus fitur bentuk dan memilih fitur warna dan tekstur menunjukkan bahwa akurasi penelitian ini lebih tinggi yaitu 97 % hal ini disebabkan perbedaan fitur yang dipilih untuk ekstraksi fitur tekstur dan warna.

Pengaruh pemilihan fitur tekstur dan warna akan dianalisis lebih lanjut pada skenario uji 2 dan 3. Untuk menunjang analisis skenario uji 1, maka akan dianalisis hasil akurasi per fitur sebagai berikut:

Tabel 4.17 Hasil Akurasi per Fitur

Fitur	Akurasi
Bentuk	39 %
Tekstur:	
Correlation	81 %
Energy	78,67 %
Homogeneity	63,67 %
Variance	63,67 %
Warna:	
Color moments 1	52,33 %
Color moments 2	93,67 %
Color moments 3	67,33%
Histogram frekuensi	52,33 %
Grey level	52,33 %

Dari hasil analisis akurasi per fitur didapatkan kesimpulan bahwa fitur bentuk menghasilkan akurasi paling rendah jika dibandingkan dengan fitur lainnya. Oleh karena itu, fitur bentuk kurang representatif untuk identifikasi penyakit pada daun tebu sehingga dapat diusulkan fitur tekstur dan warna.

1.4 Skenario Uji 2

Pada skenario uji 2 akan diteliti pengaruh pemilihan fitur tekstur. Pada penelitian sebelumnya (Camargo, 2009b) menggunakan fitur *contrast*, *correlation*, *energy* dan *homogeneity* untuk identifikasi penyakit tanaman. Penelitian ini menggunakan fitur tekstur dengan *correlation*, *energy*, *homogeneity* dan *variance* serta fitur warna dengan *color moment* 1, 2 dan 3.

Secara ringkas, fitur yang digunakan pada skenario uji 2 dapat dilihat pada tabel berikut:

Tabel 4.18 Fitur untuk Skenario Uji 2

Fitur	Camargo, 2009	Tesis
Tekstur	<ul style="list-style-type: none"> • contrast • correlation 	<ul style="list-style-type: none"> • correlation • energy

	<ul style="list-style-type: none"> • energy • homogeneity 	<ul style="list-style-type: none"> • homogeneity • variance
--	---	---

Skenario uji diujikan pada data yang sama, yaitu 300 data daun tebu dengan 100 normal, 100 memiliki penyakit karat dan 100 memiliki penyakit mosaik. Pada skenario uji 1 akan diteliti hasil pengujian akurasi untuk paduan fitur yang diusulkan pada penelitian sebelumnya kemudian membandingkannya dengan fitur yang diusulkan dalam penelitian ini.

1.4.1. Hasil Uji Skenario 2

Hasil pengujian akurasi yang dilakukan sesuai skenario 2 untuk mengetahui pengaruh pemilihan fitur tekstur dijelaskan dalam tabel berikut:

Tabel 4.19 Akurasi Skenario Uji 2

Fitur Tekstur	Akurasi
Camargo, 2009	90,33 %
Tesis	90,33 %

Hasil uji skenario 2 menunjukkan bahwa fitur yang diusulkan dalam penelitian ini sama akurat dengan penelitian sebelumnya untuk merepresentasikan fitur tekstur pada citra daun tebu.

1.4.2. Analisis Hasil Uji Skenario 2

Hasil pemilihan fitur tekstur pada penelitian sebelumnya menempati posisi atas dalam hal keakuratan sistem dibandingkan dengan keseluruhan fitur GLCM yang berjumlah 14 seperti diunjukkan dalam tabel 4.7. Namun, analisis statistik yang digunakan dalam penelitian sebelumnya memiliki 2 fitur yang merepresentasikan hal yang sama, yaitu contrast dan homogeneity. Akurasi yang tinggi pada penelitian sebelumnya karena menggunakan fitur terbatas dalam hal akurasi namun tidak menganalisis tekstur secara menyeluruh. Pada penelitian ini, menggunakan analisis tekstur GLCM yang menyeluruh dan tetap menghasilkan akurasi yang baik, yaitu 90,33 %.

1.5 Skenario Uji 3

Pada skenario uji 3 akan diteliti pengaruh pemilihan fitur warna. Pada penelitian sebelumnya (Camargo, 2009b) menggunakan fitur histogram frekuensi dan *grey level* untuk masing-masing *channel* warna. Penelitian ini menggunakan *color moments* 1, 2 dan 3 untuk merepresentasikan fitur warna. Secara ringkas, fitur yang digunakan pada skenario uji 3 dapat dilihat pada tabel berikut:

Tabel 4.20 Fitur Skenario Uji 3

Fitur	Camargo, 2009	Tesis
Warna	<ul style="list-style-type: none">• Histogram Frekuensi• <i>Grey level</i> (masing-masing channel warna)	<ul style="list-style-type: none">• Color moment 1• Color moment 2• Color moment 3

Skenario uji diujikan pada data yang sama, yaitu 300 data daun tebu dengan 100 normal, 100 memiliki penyakit karat dan 100 memiliki penyakit mosaik. Pada skenario uji 3 akan diteliti hasil pengujian akurasi untuk paduan fitur yang diusulkan pada penelitian sebelumnya kemudian membandingkannya dengan fitur yang diusulkan dalam penelitian ini.

1.5.1. Hasil Uji Skenario 3

Hasil pengujian akurasi yang dilakukan sesuai skenario 3 untuk mengetahui pengaruh pemilihan fitur tekstur dijelaskan dalam tabel berikut:

Tabel 4.21 Hasil Akurasi Skenario Uji 3

Fitur Warna	Akurasi
Camargo, 2009	52,67 %
Tesis	96 %

Hasil uji skenario 3 menunjukkan bahwa *color moments* lebih dapat merepresentasikan warna untuk identifikasi penyakit daun tebu daripada metode ekstraksi fitur warna yang diusulkan penelitian sebelumnya. Hal tersebut ditunjukkan nilai akurasi menggunakan fitur *color moment* menghasilkan akurasi 96 %.

1.5.2. Analisis Hasil Uji Skenario 3

Color moments menghasilkan nilai akurasi yang lebih tinggi dibandingkan fitur *grey level* dan histogram frekuensi, yaitu 96 %. *Color moment* merupakan pengukuran kesamaan warna antar gambar. Konsep *color moment* menyatakan probabilitas distribusi warna dapat dikenali dari moment warna, misalnya distribusi normal dapat dianalisis dari mean (*color moment 1*) dan *variance*. Jika warna sebuah citra mengikuti probabilitas distribusi tertentu maka *moment* dari distribusi tersebut dapat dipakai sebagai fitur untuk identifikasi citra berdasarkan warna.

Histogram dapat digunakan untuk merepresentasikan fitur warna karena tidak sensitif terhadap perubahan posisi dan orientasi serta memiliki akurasi yang tinggi (Singh, 2012) namun memiliki kekurangan tidak bisa menangkap hubungan spasial dari region warna sehingga kurang dapat membedakan perbedaan warna antara citra.

Penelitian yang berkembang berfokus pada ekstraksi fitur warna berdasarkan distribusi warna global. Distribusi global ini memiliki kekurangan tidak dapat menangkap informasi warna lokal. *Color correlogram* dan *color coherence vector* dapat mengkombinasikan korelasi spasial dari region warna (lokal) maupun distribusi global dari warna. Kedua metode ini lebih baik dari metode tradisional (histogram), tetapi memiliki kelemahan membutuhkan waktu komputasi yang tinggi. *Color moment* merupakan solusi dari masalah ini. Penelitian (Stricker, 1995) menyatakan bahwa 3 moment dari *color moment* lebih handal dan lebih cepat dibandingkan metode histogram.

1.6 Skenario Uji 4

Pada skenario uji 4 akan diteliti pengaruh pemilihan kombinasi fitur tekstur dan warna. Pada penelitian sebelumnya mengenai identifikasi penyakit tanaman secara umum (Camargo, 2009b) merekomendasikan fitur bentuk (*minor axis length* dan *eccentricity*), tekstur (*contrast*, *correlation*, *energy*, *homogeneity*) dan warna (histogram frekuensi dan *grey level* untuk masing-masing *channel* warna). Pada penelitian ini mengusulkan penghapusan fitur bentuk, fitur tekstur dan warna seperti terdapat pada tabel berikut:

Tabel 4.22 Fitur Skenario 4

Fitur	Camargo, 2009	Tesis
Bentuk	Menggunakan fitur bentuk: minor axis length dan eccentricity	Menghapus fitur bentuk
Tekstur	<ul style="list-style-type: none"> • contrast • correlation • energy • homogeneity 	<ul style="list-style-type: none"> • correlation • energy • homogeneity • variance
Warna	<ul style="list-style-type: none"> • Histogram Frekuensi • Grey Level masing-masing channel warna 	<ul style="list-style-type: none"> • Color moment 1 • Color moment 2 • Color moment 3

Skenario uji diujikan pada data yang sama, yaitu 300 data daun tebu dengan 100 normal, 100 memiliki penyakit karat dan 100 memiliki penyakit mosaik. Pada skenario uji 4 akan diteliti pengaruh kombinasi fitur tekstur dan warna untuk identifikasi penyakit tebu, pengujian yang dilakukan dilaksanakan dengan menguji kombinasi fitur penelitian sebelumnya dan penelitian ini.

1.6.1. Hasil Uji Skenario 4

Hasil pengujian akurasi yang dilakukan sesuai skenario 4 untuk mengetahui pengaruh kombinasi fitur dan warna dijelaskan dalam tabel berikut:

Tabel 4.23 Hasil Akurasi Skenario Uji 4

Fitur	Akurasi
Camargo, 2009	85,67 %
Tesis	97 %

1.6.2. Analisis Hasil Uji Skenario 4

Hasil uji skenario 4 menunjukkan bahwa fitur yang dipilih dalam penelitian ini lebih akurat untuk identifikasi penyakit daun tebu dibandingkan dengan kombinasi fitur yang diusulkan pada penelitian sebelumnya mengenai

identifikasi penyakit tanaman secara umum (Camargo, 2009). Hal ini menunjukkan bahwa penghapusan fitur bentuk, pemilihan fitur tekstur dengan GLCM (*correlation, energy, homogeneity* dan *variance*) dan pemilihan *color moment* 1, 2, 3 sebagai fitur warna merupakan kombinasi fitur yang dapat digunakan untuk identifikasi penyakit pada daun tebu.

Penyebab kenaikan akurasi pada kombinasi fitur yang diusulkan dalam 2 penelitian tersebut adalah penghapusan fitur bentuk karena pola penyakit karat pada tebu memiliki pola bentuk yang tidak beraturan, selain itu pada pengujian per fitur didapatkan bahwa akurasi untuk fitur bentuk memiliki nilai yang paling rendah dibandingkan fitur lainnya seperti terdapat pada skenario uji 1.

Akurasi dengan kombinasi fitur penelitian ini yang menunjukkan angka 97 % disebabkan fitur tekstur yang diusulkan menunjukkan akurasi yang tinggi yaitu 90,33 % dikombinasikan dengan fitur warna yang lebih unggul dari penelitian sebelumnya sehingga apabila kombinasi fitur yang baik tersebut digabungkan maka dapat meningkatkan akurasi.

BAB 5

KESIMPULAN DAN SARAN

Pada bab ini dijelaskan kesimpulan yang didapatkan dari hasil penelitian dan juga saran untuk penelitian selanjutnya.

1.1 Kesimpulan

Kesimpulan yang dapat diambil dari penelitian ini sebagai berikut:

1. Penghapusan fitur bentuk dapat memperbaiki akurasi untuk identifikasi penyakit daun tebu karena bentuk kurang dapat merepresentasikan pola penyakit pada daun tebu, sehingga fitur tekstur dan warna dapat diusulkan menjadi fitur yang merepresentasikan penyakit daun tebu
2. Pemilihan fitur GLCM untuk fitur tekstur yang berupa *correlation*, *energy homogeneity* dan *variance* menghasilkan akurasi yang baik yaitu 90,33 %.
3. Pemilihan fitur *color moment* 1, 2 dan 3 untuk fitur warna lebih akurat dari fitur warna menggunakan *grey level* dan histogram frekuensi dengan akurasi 96 %.
4. Kombinasi fitur tekstur dengan GLCM *correlation*, *energy*, *homogeneity*, *variance* bersama fitur warna dengan *color moment* 1,2 dan 3 merupakan kombinasi fitur yang direkomendasikan untuk identifikasi penyakit pada daun tebu dengan akurasi 97 %.

1.2 Saran

Penelitian ini menggunakan metode klasifikasi *support vector machine* (SVM) dengan kernel *linear* sehingga penelitian lanjutan dapat meneliti metode klasifikasi yang lebih baik, misalnya dengan modifikasi kernel maupun penggunaan metode klasifikasi lain.

Saat mengakuisisi citra warna dengan kamera digital, terdapat kondisi pencahayaan yang tidak konsisten. Hal itu dapat menyebabkan warna menjadi tidak sesuai dengan aslinya sehingga diperlukan proses pengoreksian warna pada citra yang direkam untuk memperkirakan warna aslinya.

BAB 5

KESIMPULAN DAN SARAN

Pada bab ini dijelaskan kesimpulan yang didapatkan dari hasil penelitian dan juga saran untuk penelitian selanjutnya.

1.1 Kesimpulan

Kesimpulan yang dapat diambil dari penelitian ini sebagai berikut:

1. Penghapusan fitur bentuk dapat memperbaiki akurasi untuk identifikasi penyakit daun tebu karena bentuk kurang dapat merepresentasikan pola penyakit pada daun tebu, sehingga fitur tekstur dan warna dapat diusulkan menjadi fitur yang merepresentasikan penyakit daun tebu
2. Pemilihan fitur GLCM untuk fitur tekstur yang berupa *correlation*, *energy* *homogeneity* dan *variance* menghasilkan akurasi yang baik yaitu 90,33 %.
3. Pemilihan fitur *color moment* 1, 2 dan 3 untuk fitur warna lebih akurat dari fitur warna menggunakan *grey level* dan histogram frekuensi dengan akurasi 96 %.
4. Kombinasi fitur tekstur dengan GLCM *correlation*, *energy*, *homogeneity*, *variance* bersama fitur warna dengan *color moment* 1,2 dan 3 merupakan kombinasi fitur yang direkomendasikan untuk identifikasi penyakit pada daun tebu dengan akurasi 97 %.

1.2 Saran

Penelitian ini menggunakan metode klasifikasi *support vector machine* (SVM) dengan kernel *linear* sehingga penelitian lanjutan dapat meneliti metode klasifikasi yang lebih baik, misalnya dengan modifikasi kernel maupun penggunaan metode klasifikasi lain.

Saat mengakuisisi citra warna dengan kamera digital, terdapat kondisi pencahayaan yang tidak konsisten. Hal itu dapat menyebabkan warna menjadi tidak sesuai dengan aslinya sehingga diperlukan proses pengoreksian warna pada citra yang direkam untuk memperkirakan warna aslinya.

DAFTAR PUSTAKA

- Abdel-Rahman, E. M., and F. B. Ahmed. 2008. "The application of remote sensing techniques to sugarcane (*Saccharum* spp. hybrid) production: a review of the literature." *International Journal of Remote Sensing* 29.13: 3753-3767.
- Agropedia. 2014. "Sugarcane Growth Stages". <http://agropedia.iitk.ac.in/content/sugarcane-growth-stages>. Tanggal akses: 22 Juni 2014.
- Albregtsen, Fritz. 1995. "Statistical texture measures computed from gray level cooccurrence matrices." *Image Processing Laboratory, Department of Informatics, University of Oslo* :1-14.
- Asraf, H. Muhammad, M. T. Nooritawati, and M. S. B. Rizam. 2012. "A Comparative Study in Kernel-Based *Support vector machine* of Kelapa sawit Leaves Nutrient Disease." *Procedia Engineering* 41 : 1353-1359.
- Camargo, A., and J. S. Smith. 2009. "An image-processing based algorithm to automatically identify plant disease visual symptoms." *Biosystems Engineering* 102.1: 9-21.
- Camargo, A., and J. S. Smith. 2009. "Image pattern classification for the identification of disease causing agents in plants." *Computers and Electronics in Agriculture* 66.2: 121-125.
- Comstock, J.C and R. A. Gilbert. 2009. "Sugarcane Mosaik Virus Disease". University of Florida: Florida Sugarcane Handbook.
- Connors, Richard W., and Charles A. Harlow. 1980. "A theoretical comparison of texture algorithms." *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 3 : 204-222.
- Cortes, Corinna, and Vladimir Vapnik. 1995. "Support vector machine." *Machine learning* 20.3 : 273-297.
- Elish, Karim O., and Mahmoud O. Elish. 2008. "Predicting defect-prone software modules using support vector machines." *Journal of Systems and Software* 81.5 : 649-660.

- Fitriawan, Aries, et al. 2013. "Classification System for Jamu Efficacy based on Formula using Support vector Machine". International Conference on Advanced Computer Science and Information Systems (ICACSIS): 291-295
- Gadelmawla, E. S. 2004. "A vision system for surface roughness characterization using the gray level co-occurrence matrix." *NDT & E International* 37.7: 577-588.
- Grisham, Michael P., Richard M. Johnson, and Paul V. Zimba. 2010. "Detecting Sugarcane yellow leaf virus infection in asymptomatic leaves with hyperspectral remote sensing and associated leaf pigment changes." *Journal of virological methods* 167.2 : 140-145.
- Haralick, Robert M., Karthikeyan Shanmugam, and Its' Hak Dinstein. 1973. "Textural features for image classification." *Systems, Man and Cybernetics, IEEE Transactions on* 6 : 610-621.
- Herdiyeni, Yeni, and Mayanda Mega Santoni. 2012. "Combination of morphological, Local Binary Pattern Variance and *color moments* features for Indonesian medicinal plants identification." *Advanced Computer Science and Information Systems (ICACSIS), International Conference on. IEEE.*
- Honeycutt, Chris Ebey, and Roy Plotnick. 2008. "Image analysis techniques and gray-level co-occurrence matrices (GLCM) for calculating bioturbation indices and characterizing biogenic sedimentary structures." *Computers & Geosciences* 34.11: 1461-1472.
- Kadir, Abdul dan Adhi Susanto. 2014. "Teori dan Aplikasi Pengolahan Citra". Penerbit Andi.
- Kavitha, Ch, Dr B. Prabhakara Rao, and Dr A. Govardhan. 2011. "Image retrieval based on color and texture features of the image sub-blocks." *International Journal of Computer Applications* 15.7.
- Kekre, H. B., et al. 2010. "Image Retrieval using Texture Features extracted from GLCM, LBG and KPE." *International Journal of Computer Theory and Engineering* 2.5: 695-700.

- Kodituwakku, S. R., and S. Selvarajah. 2012. "Comparison of color features for image retrieval." *Indian Journal of Computer Science and Engineering* 1.3: 207-211.
- Li, Daoliang, Wenzhu Yang, and Sile Wang. 2010. "Classification of foreign fibers in cotton lint using machine vision and multi-class *support vector machine*." *Computers and electronics in agriculture* 74.2: 274-279.
- Li-jie, Yu, Li De-sheng, and Zhou Guan-ling. 2009. "Automatic Image Segmentation Base on Human Color Perceptions." *International Journal of Image, Graphics and Signal Processing (IJIGSP)* 1.1: 25.
- Manivannan, K., et al. 2012. "Particulate matter characterization by gray level co-occurrence matrix based support vector machines." *Journal of hazardous materials* 223: 94-103.
- Mathworks. 2014. Convert RGB to Gray. <http://www.mathworks.com/help/images/ref/rgb2gray.html>. Tanggal akses: 22 Juni 2014.
- Patil, Jayamala K., and Raj Kumar. 2011. "Color Feature Extraction of Tomato Leaf Diseases." *International Journal of Engineering Trends and Technology* 2.2: 72-74.
- Pascale, D. 2003. "A Review of RGB Color Spaces". The BabelColor Company, 5700 Hector Desloges, Montreal (Quebec), Canada H1T 3Z6.
- Phadikar, Santanu, Jaya Sil, and Asit Kumar Das. 2013. "Rice diseases classification using feature selection and rule generation techniques." *Computers and Electronics in Agriculture* 90: 76-85.
- Pusat Penelitian Perkebunan Gula Indonesia (P3GI). 2008. "Konsep Peningkatan Rendemen". <http://sugarresearch.org/wp-content/uploads/2008/12/konsep-peningkatan-rendemen.pdf>. Tanggal akses: 22 Juni 2014.
- Pusat Penelitian Perkebunan Gula Indonesia (P3GI). 2009. "Deskripsi tebu varietas BL". <http://sugarresearch.org/wp-content/uploads/2009/04/bl.pdf>. Tanggal akses: 22 Juni 2014.
- Raid, R. N and J.C. Comstock. 2006. "Sugarcane Rust Virus Disease". University of Florida: Florida Sugarcane Handbook.
- Rizaldi, Dedy. 2014. "Profil Tebu". http://kppbumn.depkeu.go.id/Industrial_Profile/PK4/Profil%20Tebu-1.htm. Tanggal akses: 22 Juni 2014.

- Shabanzade, Maliheh, Morteza Zahedi, and Seyyed Amin Aghvami. 2011. "Combination of local descriptors and global features for leaf recognition." *Signal and Image Processing: An International Journal (SIPIJ)*. v2 i3: 23-31.
- Shahbudin, S., et al. 2008. "Multi-class Support Vector Machine for human posture classification using a simplified shock graph". *Information Theory and Its Applications, International Symposium on.IEEE*.
- Zhang, Bingsen. & Li, Hanchun. 2008. "Research on Application for Color Matching in Textile Dyeing Based on Numerical Analysis", *International Conference on Computer Science and Software Engineering*:357-360.

BIOGRAFI PENULIS

Ratih Kartika Dewi merupakan anak pertama dari 3 bersaudara, lahir di Malang pada tanggal 20 Mei 1989. Penulis menempuh pendidikan di SDN ketabang 3 Surabaya, SMP Negeri 6 Malang, SMA Negeri 3 Malang. Kemudian penulis melanjutkan pendidikan S1 di Teknik Informatika, Universitas Brawijaya Malang dari tahun 2007 hingga tahun 2011. Pada tahun 2012 hingga 2014 penulis melanjutkan pendidikan S2 di Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember (ITS) Surabaya dengan mengambil bidang minat Komputasi Cerdas dan Visualisasi. Saat ini penulis menjadi asisten dosen di Universitas Brawijaya Malang. Bidang penelitian yang diminati penulis adalah pengolahan citra digital dan pengembangan aplikasi perangkat bergerak. Penulis dapat dihubungi melalui email ratihkartikad@ub.ac.id.



DAFTAR LAMPIRAN

Tabel pengujian akurasi skenario uji 1.....	65
Tabel pengujian akurasi skenario uji 2.....	65
Tabel pengujian akurasi skenario uji 3.....	65
Tabel pengujian akurasi skenario uji 4.....	66

LAMPIRAN

Tabel pengujian akurasi skenario uji 1

Camargo		Tesis	
T1	91	T1	98
T2	72	T2	93
T3	8	T3	98
F1	9	F1	2
F2	28	F2	7
F3	92	F3	2

Tabel pengujian akurasi skenario uji 2

Camargo		Tesis	
T1	93	T1	93
T2	83	T2	85
T3	94	T3	92
F1	7	F1	7
F2	17	F2	15
F3	6	F3	8

Tabel pengujian akurasi skenario uji 3

Camargo		Tesis	
T1	49	T1	97
T2	47	T2	92
T3	87	T3	97
F1	51	F1	3
F2	53	F2	8
F3	13	F3	3

Tabel pengujian akurasi skenario uji 4

Camargo		Tesis	
T1	91	T1	98
T2	72	T2	93
T3	8	T3	98
F1	9	F1	2
F2	28	F2	7
F3	92	F3	2