

**KLASIFIKASI PENYAKIT DAUN TANAMAN KACANG TANAH
BERDASARKAN TEKSTUR DAN WARNA MENGGUNAKAN
METODE *MULTICLASS SUPPORT VECTOR MACHINE***

TESIS

**PROGRAM MAGISTER TEKNIK ELEKTRO
MINAT SISTEM KONTROL DAN ELEKTRONIKA (SKE)**

**Ditujukan untuk memenuhi persyaratan
Memperoleh gelar Magister Teknik**



**BRAHMA RATIH RAHAYU FAKHRUNNIA
NIM 176060300111007**

**UNIVERSITAS BRAWIJAYA
FAKULTAS TEKNIK
MALANG
2021**

**KLASIFIKASI PENYAKIT DAUN TANAMAN KACANG TANAH
BERDASARKAN TEKSTUR DAN WARNA MENGGUNAKAN
METODE *MULTICLASS SUPPORT VECTOR MACHINE***

TESIS

**PROGRAM MAGISTER TEKNIK ELEKTRO
MINAT SISTEM KONTROL DAN ELEKTRONIKA (SKE)**

**Ditujukan untuk memenuhi persyaratan
Memperoleh gelar Magister Teknik**



**BRAHMA RATIH RAHAYU FAKHRUNNIA
NIM 176060300111007**

**UNIVERSITAS BRAWIJAYA
FAKULTAS TEKNIK
MALANG
2021**

TESIS

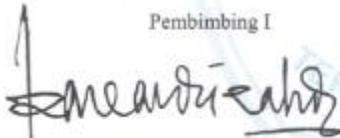
**KLASIFIKASI PENYAKIT DAUN TANAMAN KACANG TANAH
BERDASARKAN TEKSTUR DAN WARNA MENGGUNAKAN
METODE *MULTICLASS SUPPORT VECTOR MACHINE***

**BRAHMA RATIH RAHAYU FAKHRUNNIA
NIM. 176060300111007**

telah dipertahankan di depan penguji
pada Tanggal **14 Juli 2021**
dinyatakan telah memenuhi syarat
untuk memperoleh gelar **Magister Teknik**

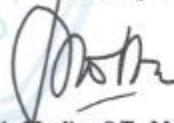
Komisi Pembimbing

Pembimbing I



Dr.Eng. Panca Mudjirahardjo, S.T., M.T.

Pembimbing II



M. Aziz Muslim, S.T., M.T., Ph.D.

Malang, **21 JUL 2021**

Universitas Brawijaya

Fakultas Teknik, Jurusan Teknik Elektro

Plt. Ketua Jurusan Teknik Elektro



M. Aziz Muslim, S.T., M.T., Ph.D.

NIP. 197412032000121001

IDENTITAS TIM PENGUJI

Judul Tesis :

Klasifikasi Penyakit Daun Tanaman Kacang Tanah Berdasarkan Tekstur dan Warna menggunakan Metode *Multiclass Support Vector Machine*

Nama Mahasiswa : Brahma Ratih Rahayu Fakhrunnia
NIM : 176060300111007
Program Studi : Teknik Elektro

KOMISI PEMBIMBING :

Ketua : Dr. Eng. Panca Mudjirahardjo, S.T., M.T.
Anggota : Muhammad Aziz Muslim, S.T., M.T., Ph.D.

TIM DOSEN PENGUJI :

Dosen Penguji 1 : Rahmadwati, S.T., M.T., Ph.D.
Dosen Penguji 2 : Dr. Ir. Muhammad Aswin, M.T.
Tanggal Ujian : 14 Juli 2021
SK Penguji :

PERNYATAAN ORISINALITAS TESIS

Saya menyatakan dengan sebenar-benarnya bahwa sepanjang pengetahuan Saya dan berdasarkan hasil penelusuran berbagai karya ilmiah, gagasan dan masalah ilmiah yang diteliti dan diulas di dalam Naskah Tesis ini adalah asli dari pemikiran Saya. Tidak terdapat karya ilmiah yang pernah diajukan oleh orang lain untuk memperoleh gelar akademik di suatu Perguruan Tinggi, dan tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang secara tertulis dikutip dalam naskah ini dan disebutkan dalam sumber kutipan dan daftar pustaka.

Apabila ternyata di dalam naskah Tesis ini dapat dibuktikan terdapat unsur-unsur jiplakan, Saya bersedia Tesis dibatalkan, serta diproses sesuai dengan peraturan perundang-undangan yang berlaku (UU No. 20 tahun 2003, Pasal 25 Ayat 2 dan Pasal 70).

Malang, 19 Juli 2021

Mahasiswa,



Nama : **BRAHMA RATIH RAHAYU FAKHRUNNIA**

NIM : **176060300111007**

PM : **TEKNIK ELEKTRO**

PROGRAM MAGISTER TEKNIK ELEKTRO

*Karya ilmiah ini kutujukan kepada
Papa dan Mama tercinta,
Kakak, adik dan suamiku tersayang*

ABSTRAK

Brahma Ratih Rahayu Fakhrunnia, Jurusan Teknik Elektro, Fakultas Teknik Universitas Brawijaya, Juni 2021, *Klasifikasi Penyakit Daun Tanaman Kacang Tanah Berdasarkan Tekstur dan Warna Menggunakan Metode Multiclass Support Vector Machine*, Dosen Pembimbing: Panca Mudjirahardjo dan Muhammad Aziz Muslim.

Penyakit tanaman merupakan salah satu pembatas penting pada budidaya tanaman kacang tanah di Indonesia, karena dapat menurunkan kualitas dan kuantitas dari hasil yang dicapai. Pengenalan jenis penyakit pada daun tanaman kacang tanah pada umumnya masih secara manual menggunakan pengamatan mata. Sehingga diperlukan penerapan teknologi yang tentunya bisa menjadi salah satu alternatif untuk diterapkan pada budidaya tanaman kacang tanah terutama untuk pengenalan dan pengendalian penyakit tanaman.

Pada penelitian ini menyajikan aplikasi pengembangan teknologi, yaitu pengolahan citra digital yang digunakan untuk mengenali ciri penyakit daun kacang tanah yang terserang penyakit berdasarkan ekstraksi ciri tekstur *Gray Level Co-occurrence Matrix* (GLCM) dan ekstraksi ciri warna HSV. Hasil dari ekstraksi ciri tersebut akan diklasifikasikan menggunakan metode *Multiclass SVM* dengan strategi *Directed Acyclic Graph Support Vector Machine* (DAGSVM) untuk menentukan label kelas dari input data daun tanaman kacang tanah. Hasil dari proses klasifikasi penyakit daun kacang tanah dengan menggunakan *input* ciri tekstur GLCM dan ciri warna HSV serta diklasifikasikan dengan menggunakan metode *Multiclass SVM* dengan strategi DAGSVM menunjukkan bahwa dengan menggunakan kernel RBF memberikan hasil akurasi lebih tinggi bila dibandingkan dengan menggunakan kernel linear dan kernel *polynomial*. Hal ini dapat dilihat dari hasil penelitian bahwa klasifikasi menggunakan kernel RBF memberikan hasil tertinggi dengan menggunakan jarak $d=1$ dengan sudut GLCM 90° dengan nilai akurasi mencapai 99,2% pada kelas bercak daun, 98.3 % pada kelas karat daun, 99.2% pada kelas bercak mata, 100% pada kelas daun normal dan 100% pada kelas daun lain.

Kata kunci : kacang tanah, GLCM, HSV, *Multiclass SVM*, DAGSVM

SUMMARY

Brahma Ratih Rahayu Fakhrunnia, *Department of Electronics Engineering, Faculty of Engineering, University of Brawijaya, Juni 2021, Classification of Peanut Leaf Diseases Based on Texture and Color using the Multiclass Support Vector Machine Method, Academic Supervisor: Panca Mudjirahardjo and Muhammad Aziz Muslim.*

Plant disease is one of the important limitations on peanut cultivation in Indonesia, because it can reduce the quality and quantity of the results achieved. In general, the introduction of diseases on the leaves of peanut plants is still done manually using eye observation. So it is necessary to apply technology which can certainly be an alternative for peanut cultivation, especially for the introduction and control of plant diseases.

This study presents the application of technology development, namely digital image processing that is used to identify disease characteristics of peanut leaves that are attacked by disease based on texture feature extraction of Gray Level Co-occurrence Matrix (GLCM) and HSV color feature extraction. The results of the feature extraction will be classified using the Multiclass SVM method with the Directed Acyclic Graph Support Vector Machine (DAGSVM) strategy to determine the class label of the peanut leaf data input. The results of the peanut leaf disease classification process using input the GLCM texture feature and the color feature of the HSV and classified using the Multiclass SVM method with the DAGSVM strategy show that using a RBF kernel gives higher accuracy results when compared to using a linear kernel and polynomial kernel. It can be seen from the results of the study that the classification using a RBF kernel gives the highest results by using a distance of $d=1$ with a GLCM angle of 90° with an accuracy value of 99.2% in the leaf spot class, 98.3% in the leaf rust class, 99.2% in eye spot class, 100% in normal leaf class and 100% in other leaf class.

Keywords : peanut, GLCM, HSV, Multiclass SVM, DAGSVM

KATA PENGANTAR

Alhamdulillah, puji syukur penulis ucapkan kepada Allah SWT karena atas rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan tesis yang berjudul “Klasifikasi Penyakit Daun Tanaman Kacang Tanah Berdasarkan Tekstur dan Warna Menggunakan Metode *Multiclass support Vector Machine*” sebagai salah satu persyaratan dalam menyelesaikan studi di Program Studi Teknik Elektro Universitas Brawijaya.

Penulis menyadari bahwa tesis ini tidak dapat terselesaikan tanpa bantuan dan bimbingan dari berbagai pihak. Oleh karena itu, penulis mengucapkan terimakasih kepada:

1. Bapak Dr. Eng. Panca Mudjirahardjo, ST., MT. selaku Dosen Pembimbing I yang telah memberikan bimbingan, arahan, serta meluangkan waktunya sehingga tesis ini dapat terselesaikan.
2. Bapak Muhammad Aziz Muslim, S.T., MT. Ph.D. selaku Dosen Pembimbing II yang telah memberikan bimbingan, arahan, serta meluangkan waktunya sehingga tesis ini dapat terselesaikan.
3. Ibu Rahmadwati, S.T., M.T., Ph.D. selaku Dosen Penguji yang telah memberikan bimbingan, arahan, serta meluangkan waktunya sehingga tesis ini dapat terselesaikan.
4. Bapak Dr. Ir. Muhammad Aswin, M.T. selaku Dosen Penguji yang telah memberikan bimbingan, arahan, serta meluangkan waktunya sehingga tesis ini dapat terselesaikan.
5. Ibu Ir. Diding Rachmawati selaku Peneliti Madya/Manajer Teknis Laboratorium Hama Penyakit Balai Pengkajian Teknologi Pertanian (BPPT) Jawa Timur.
6. Segenap Bapak dan Ibu Dosen atas kesediaan membagi ilmunya kepada penulis selama menempuh pendidikan di Universitas Brawijaya.
7. Segenap staf dan Karyawan Program Studi Teknik Elektro yang telah memberikan bantuan kepada penulis selama menyelesaikan tesis ini.
8. Orang tua, suami, dan segenap keluarga besar atas dukungan, motivasi dan kasih sayang terhadap penulis.
9. Teman-teman Program Studi Teknik Elektro angkatan 2017 yang selalu memberikan bantuan dan motivasi dalam menyelesaikan tesis ini.
10. Semua pihak yang telah membantu terselesaikannya tesis ini yang tidak dapat penulis sebutkan satu per satu.

Penulis menyadari bahwa tesis ini masih memiliki banyak kekurangan dan jauh dari sempurna karena keterbatasan pengetahuan dan materi yang dimiliki oleh penulis. Oleh karena itu, saran dan kritik yang membangun dari semua pihak sangat diharapkan demi penyempurnaan selanjutnya. Semoga tesis ini dapat bermanfaat dan berguna bagi semua pihak.

Malang, 14 Juli 2021

Penulis

DAFTAR ISI

JUDUL	i
LEMBAR PENGESAHAN	ii
IDENTITAS TIM PENGUJI	iii
PERNYATAAN ORISINALITAS TESIS	iv
LEMBAR PERUNTUKAN	v
RIWAYAT HIDUP	vi
LEMBAR UCAPAN TERIMAKASIH	vii
ABSTRAK	viii
SUMMARY	ix
KATA PENGANTAR	x
DAFTAR ISI	xii
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xvi
BAB I ENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	2
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	3
BAB II TINJAUAN PUSTAKA	4
2.1 Penelitian Terkait.....	4
2.2 Tanaman Kacang Tanah	10
2.2.1 Morfologi Tanaman Kacang Tanah	10
2.2.2 Manfaat Kacang Tanah	10
2.2.3 Penyakit Daun Tanaman Kacang Tanah	11
2.3 Pengertian Citra Digital	12
2.4 Pengolahan Citra Digital	13
2.5 Ruang Warna	14
2.5.1 Ruang Warna RGB.....	14
2.5.2 Ruang Warna L*a*b*.....	14
2.5.3 Ruang Warna HSV	15
2.6 K-means.....	16

2.7	Ekstraksi Ciri	17
2.7.1	Gray Level Co-occurrence Matrix (GLCM)	17
2.8	Klasifikasi	21
2.9	Support Vector Machine (SVM).....	22
2.9.1	SVM Linear	22
2.9.2	SVM NonLinear	23
2.9.3	Directed Acyclic Graph Support Vector Machine (DAGSVM)	24
2.10	Evaluasi.....	25
BAB III KERANGKA KONSEP PENELITIAN		27
3.1	Kerangka Teori Penelitian	27
3.2	Hipotesis	31
BAB IV METODE PENELITIAN		32
4.1	Studi Literatur	32
4.2	Analisis Keperluan Sistem.....	32
4.3	Pengumpulan Dataset.....	33
4.4	Perancangan Sistem	34
4.4.1	Input Citra.....	36
4.4.2	Pre-processing	36
4.4.3	Segmentasi Citra.....	36
4.4.4	Ekstraksi Ciri	37
4.4.5	Klasifikasi <i>Multiclass-SVM</i>	40
4.5	Pengujian.....	43
BAB V HASIL DAN PEMBAHASAN.....		44
5.1	Perancangan Sistem	44
5.1.1	Preprocessing.....	44
5.1.2	Segmentasi.....	44
5.1.3	Ekstraksi Ciri	52
5.1.4	Klasifikasi.....	58
5.2	Hasil Penelitian dan Pembahasan	67
5.2.1	Pengujian akurasi, sensitivitas dan spesifisitas.....	67
5.2.2	Pengujian <i>Confusion matrix</i>	82
BAB VI KESIMPULAN		95
6.1	Kesimpulan	95
6.2	Saran	95
DAFTAR PUSTAKA		

DAFTAR TABEL

Tabel 2.1 Penelitian yang relevan	6
Tabel 2.2 Area kerja matriks	18
Tabel 5.1 Ekstraksi ciri data latih.....	59
Tabel 5.2 Data yang dilatih pada model klasifikasi 1	59
Tabel 5.3 Nilai alpha dan bias model klasifikasi 1.....	60
Tabel 5.4 Data yang dilatih pada model klasifikasi 2	60
Tabel 5.5 alpha dan bias model klasifikasi 2	60
Tabel 5.6 Data yang dilatih pada model klasifikasi 3	61
Tabel 5.7 Nilai alpha dan bias model klasifikasi 3.....	61
Tabel 5.8 Data yang dilatih pada model klasifikasi 4	61
Tabel 5.9 Nilai alpha dan bias model klasifikasi 4.....	61
Tabel 5.10 Data yang dilatih pada model klasifikasi 5	62
Tabel 5.11 Nilai alpha dan bias model klasifikasi 5.....	62
Tabel 5.12 Data yang dilatih pada model klasifikasi 6	62
Tabel 5.13 Nilai alpha dan bias optimal model klasifikasi 6	62
Tabel 5.14 Data yang dilatih pada model klasifikasi 7	63
Tabel 5.15 Nilai alpha dan bias optimal model klasifikasi 7	63
Tabel 5.16 Data yang dilatih pada model klasifikasi 8	63
Tabel 5.17 Nilai alpha dan bias model klasifikasi 8.....	63
Tabel 5.18 Data yang dilatih pada model klasifikasi 9	64
Tabel 5.19 Nilai alpha dan bias optimal model klasifikasi 9	64
Tabel 5.20 Data yang dilatih pada model klasifikasi 10	64
Tabel 5.21 Nilai alpha dan bias model klasifikasi 10.....	64
Tabel 5.22 Hasil ekstraksi ciri data uji	65
Tabel 5.23 Hasil pengujian di node 1	66
Tabel 5.24 Hasil pengujian di node 2.....	66
Tabel 5.25 Hasil pengujian di node 3.....	66
Tabel 5.26 Hasil pengujian di node 4.....	66
Tabel 5.27 Hasil pengujian di node 5.....	66
Tabel 5.28 Hasil pengujian di node 6.....	67
Tabel 5.29 Hasil pengujian di node 7.....	67
Tabel 5.30 Hasil pengujian di node 8.....	67

Tabel 5.31 Hasil pengujian di node 9	67
Tabel 5.32 Hasil pengujian di node 10	67
Tabel 5.33 Performansi kinerja klasifikasi untuk kernel polynomial input ciri GLCM.....	68
Tabel 5.34 Performansi kinerja klasifikasi untuk kernel linear input ciri GLCM.....	70
Tabel 5.35 Performansi kinerja klasifikasi untuk kernel RBF input ciri GLCM	72
Tabel 5.36 Performansi kinerja klasifikasi kernel polynomial input ciri HSV	73
Tabel 5.37 Hasil performansi klasifikasi menggunakan kernel linear input ciri HSV	75
Tabel 5.38 Hasil performansi klasifikasi menggunakan kernel RBF input ciri HSV	76
Tabel 5.39 Performansi kinerja klasifikasi kernel polynomial input ciri GLCM+HSV	77
Tabel 5.40 Performansi kinerja klasifikasi kernel linear input ciri GLCM + ciri HSV	79
Tabel 5.41 Performansi kinerja klasifikasi kernel RBF input ciri GLCM + ciri HSV	81
Tabel 5.42 Confusion matrix klasifikasi dengan kernel polynomial input ciri GLCM.....	83
Tabel 5.43 Confusion matrix klasifikasi dengan kernel linear dengan input ciri GLCM ...	84
Tabel 5.44 Confusion matrix klasifikasi dengan kernel RBF dengan input ciri GLCM.....	85
Tabel 5.45 Confusion matrix hasil klasifikasi kernel polynomial input ciri HSV	86
Tabel 5.46 Confusion matrix klasifikasi menggunakan kernel linear input ciri HSV	87
Tabel 5.47 Confusion matrix klasifikasi menggunakan kernel RBF input ciri HSV	87
Tabel 5.48 Confusion matrix klasifikasi kernel polynomial input ciri GLCM + ciri HSV .	88
Tabel 5.49 Confusion matrix klasifikasi kernel linear input ciri GLCM + ciri HSV	89
Tabel 5.50 Confusion matrix klasifikasi kernel RBF input ciri GLCM + ciri HSV	90
Tabel 5.51 Waktu komputasi.....	92

DAFTAR GAMBAR

Gambar 2.1 Penyakit bercak daun.....	11
Gambar 2.2 Penyakit karat daun tanaman kacang tanah.....	12
Gambar 2.3 Penyakit bercak mata daun tanaman kacang tanah	12
Gambar 2.4 Diagram kromasitas CIE	15
Gambar 2.5 Matriks asal	18
Gambar 2.6 Pembentukan matriks kookurensi dari matriks asal	18
Gambar 2.7 Pembentukan matriks transpose	19
Gambar 2.8 GLCM Simetris	19
Gambar 2.9 GLCM normalisasi	19
Gambar 2.10 Batas keputusan yang mungkin untuk set data.....	22
Gambar 2.11 Ilustrasi klasifikasi dengan metode DAGSVM	25
Gambar 3.1 Metode untuk klasifikasi penyakit daun kacang tanah.....	28
Gambar 3.2 Kerangka teori peneitian.....	29
Gambar 4.1 Metode Penelitian.....	32
Gambar 4.2 Akuisisi citra (a) box keadaan terbuka (tampak depan), (b) box keadaan tertutup (tampak depan), (c) box keadaan tertutup (tampak atas).....	34
Gambar 4.3 Diagram alir perancangan sistem	35
Gambar 4.4 Diagram alir input citra	36
Gambar 4.5 Diagram alir pre-processing	36
Gambar 4.6 Diagram alir segmentasi	37
Gambar 4.7 Diagram alir GLCM	39
Gambar 4.8 Bagan ekstraksi ciri warna HSV	40
Gambar 4.9 Klasifikasi DAGSVM	41
Gambar 4.10 Bagan dari perhitungan akurasi	43
Gambar 4.11 Bagan dari perhitungan spesifisitas	43
Gambar 4.12 Bagan dari perhitungan sensitivitas.....	43
Gambar 5.1 Sampel data RGB citra daun kacang tanah	45
Gambar 5.2 Sampel data citra daun kacang tanah dalam RGB.....	45
Gambar 5.3 Sampel data XYZ	45
Gambar 5.4 (a) sampel data $f(X)$, (b) sampel data $f(Y)$, dan (c) sampel data $f(Z)$	46
Gambar 5.5 Sampel data LAB citra daun kacang tanah.....	47
Gambar 5.6 Sampel daun kacang tanah dalam ruang warna LAB lain.....	47

Gambar 5.7 Sampel data komponen *a dan *b	48
Gambar 5.8 Sampel data centroid secara acak	48
Gambar 5.9 Sampel data hasil perhitungan manhattan distance	49
Gambar 5.10 Sampel hasil pengelompokan centroid terdekat	49
Gambar 5.11 Sampel data nilai centroid baru	49
Gambar 5.12 Hasil proses K-means clustering dengan K=2.....	50
Gambar 5.13 Sampel daun kacang tanah dari filling objek normal	50
Gambar 5.14 Sampel daun kacang tanah dari proses subtraction	51
Gambar 5.15 Sampel dari proses bwareaopen pada citra daun kacang tanah	51
Gambar 5.16 Sampel hasil dari segmentasi citra daun kacang tanah.....	52
Gambar 5.17 Sampel hasil segmentasi citra daun kacang tanah kurang sempurna	52
Gambar 5.18 Sampel daun kacang tanah dalam grayscale.....	53
Gambar 5.19 Sampel matriks kookurensi dengan sudut	54
<i>Gambar 5.20</i> Sampel matriks normalisasi dengan sudut	55
<i>Gambar 5.21</i> Sampel dari ekstraksi ciri tekstur GLCM dengan sudut	56
Gambar 5.22 Sampel hasil perhitungan (a) data H, (b) data S dan (c) data V	57
Gambar 5.23 Sampel hasil perhitungan nilai mean H, mean S dan mean V.....	58
Gambar 5.24 Grafik hasil performansi klasifikasi kernel polynomial input ciri GLCM	69
Gambar 5.25 Grafik hasil performansi klasifikasi kernel linear input ciri GLCM	71
Gambar 5.26 Grafik hasil performansi klasifikasi kernel RBF dengan input ciri GLCM ..	72
Gambar 5.27 Grafik persentase performansi klasifikasi polynomial input ciri HSV	74
Gambar 5.28 Grafik hasil performansi klasifikasi kernel linear dengan input ciri HSV	75
Gambar 5.29 Grafik hasil persentase performansi klasifikasi kernel RBF input ciri HSV .	76
Gambar 5.30 Grafik performansi klasifikasi polynomial input ciri GLCM + ciri HSV	78
Gambar 5.31 Grafik performansi klasifikasi kernel linear input ciri GLCM + ciri HSV ...	80
Gambar 5.32 Grafik performansi klasifikasi kernel RBF input ciri GLCM + ciri HSV	82
Gambar 5.33 Hasil klasifikasi penyakit daun kacang tanah.....	91

BAB I

PENDAHULUAN

1.1 Latar Belakang

Tanaman kacang tanah (*Arachis Hypogaeae L.*) adalah salah satu jenis palawija yang banyak ditanaman oleh petani di Indonesia dan dikenal sebagai sumber lemak nabati dan protein yang penting bagi sebagian penduduk Indonesia. Selain itu manfaat kacang tanah adalah sebagai tanaman “Peningkat Pendapatan Petani”, karena mampu meningkatkan kesejahteraan dan pendapatan petani. Hasil panen dari tanaman kacang tanah mampu memberikan harga jual yang relatif tinggi. Sebagai sampel, pada bulan Juli 2021 harga kacang tanah di Jawa Timur, yaitu Rp 26.194/kg, kedelai Rp. 12.833/kg dan kacang hijau Rp. 23.542/kg, berdasarkan sampel tersebut dapat dilihat bahwa harga jual kacang tanah lebih tinggi daripada kedelai serta kacang hijau (Disperindag Jawa Timur, 2021).

Saat ini permintaan terhadap kacang tanah semakin pesat dari tahun ke tahun. Pesatnya permintaan ini akibat pertumbuhan konsumsi dan banyaknya jenis olahan yang memanfaatkan kacang tanah. Namun, di Indonesia hasil produksi kacang tanah tidak mampu mencukupi kebutuhan konsumsi masyarakat. Menurut Badan Pusat Statistik dan Kementerian Pertanian (2018) produksi terhadap kacang tanah di Indonesia tahun 2014 sebesar 638,896 ton, pada tahun 2015 sebesar 605,449 ton, ketika tahun 2016 yaitu 570,477 ton, saat tahun 2017 yaitu 495,447 ton serta tahun 2018 yaitu 512,198 ton. Berdasarkan hasil produksi kacang tanah yang terus menurun setiap tahunnya membuat pemerintah terus meningkatkan hasil produksi kacang tanah dan tetap mengutamakan harga jual dari kacang tanah.

Dalam proses peningkatan produksi kacang tanah, banyak faktor yang mempengaruhi kualitas dan kuantitas dari hasil produksi kacang tanah, salah satunya adalah hama dan penyakit. Virus, bakteri dan jamur merupakan penyebab adanya penyakit pada tanaman kacang tanah. Penyakit tanaman kacang tanah bisa dikenali berdasarkan tanda dan gejala penyakit. Gejala penyakit yang mudah untuk diidentifikasi adalah pada bagian daun. Beberapa penyakit yang menyerang daun tanaman kacang tanah yang disebabkan oleh jamur adalah karat daun, bercak daun dan bercak mata. Penyakit karat daun dan bercak daun dapat menyebabkan kegagalan panen mencapai 50% (Hardaningsih dan Sumartini, 2015).

Selama ini cara untuk mengidentifikasi penyakit pada daun tanaman kacang tanah dilakukan petani dengan pengamatan mata terbuka, namun dengan menggunakan teknik ini

seringkali tidak teridentifikasi dengan akurat. Berdasarkan wawancara secara langsung kepada petani di lapangan, beberapa dari petani awam terhadap jenis penyakit pada daun tanaman kacang tanah. Sehingga diperlukan penerapan teknologi di bidang pertanian, yaitu alat bantu untuk mengidentifikasi jenis penyakit pada daun tanaman kacang tanah khususnya pada daun berpenyakit yang memiliki ciri kerusakan yang berbeda.

Penerapan teknologi yang dapat digunakan adalah pengolahan citra digital. Aplikasi dari pengolahan citra digital digunakan untuk mengenali karakteristik dari citra daun yang terkena penyakit. Karakteristik ini dapat diperoleh melalui proses ekstraksi ciri. Teknik ekstraksi ciri, yaitu proses yang digunakan untuk memperoleh karakteristik dari sebuah objek, yang merupakan ciri atau karakteristik dari objek tersebut yang dapat digunakan untuk membedakan dengan objek lainnya. Beberapa jenis pengambilan ciri yang dapat digunakan adalah pengambilan ciri dari ekstraksi tekstur, yaitu karakteristik yang dimiliki oleh citra dalam hal ini adalah susunan pola tertentu yang teratur dari konfigurasi piksel pada suatu citra dan ekstraksi ciri warna, yaitu membedakan antar objek berdasarkan warna pada citra. Kemudian, klasifikasi yaitu algoritma yang bisa mengklasifikasikan objek dengan *input* berupa karakteristik ciri-ciri dari objek tersebut.

Dalam penelitian ini didesain suatu sistem terkomputerisasi untuk mengklasifikasikan penyakit daun tanaman kacang tanah dengan bantuan software MATLAB. Metode yang digunakan adalah metode GLCM sebagai ekstraksi untuk ciri tekstur dan HSV sebagai ekstraksi untuk ciri warna. *Multiclass* SVM dengan pendekatan DAGSVM digunakan sebagai metode klasifikasi. Hasil dari pemrosesan citra ini didapatkan hasil dari klasifikasi berdasarkan jenis penyakit daun tanaman kacang tanah. Jenis penyakit yang merupakan identifikasi dari penelitian ini adalah bercak daun, karat daun dan bercak mata pada tanaman kacang tanah.

1.2 Rumusan Masalah

Rumusan masalah berdasarkan latar belakang yang telah dijelaskan adalah sebagai berikut :

- 1) Bagaimana ekstraksi ciri tekstur dengan metode GLCM dan ekstraksi ciri warna dengan ruang warna HSV pada citra penyakit daun tanaman kacang tanah?
- 2) Bagaimana performansi sistem klasifikasi penyakit daun kacang tanah menggunakan metode *Multiclass* SVM dengan pendekatan DAGSVM berdasarkan hasil ciri GLCM dan ciri HSV ?

1.3 Batasan Masalah

Batasan penelitian seperti pada keterangan berikut :

- 1) Citra daun terkena penyakit dan daun sehat diperoleh dari lapangan, dengan proses pengambilan citra, daun diletakkan di dalam *lighting box* dan difoto dengan menggunakan kamera dengan format.JPEG.
- 2) Citra daun tanaman kacang tanah yang digunakan adalah citra daun yang telah di validasi secara manual oleh ahli hama dan penyakit tanaman BPTP Jawa Timur.
- 3) Program yang digunakan menggunakan MATLAB.
- 4) Masukan dalam sistem berupa citra dua dimensi dalam ruang warna *Red, Green, Blue* (RGB).
- 5) Penyakit daun yang diidentifikasi adalah bercak daun, karat daun, dan bercak mata.
- 6) Bagian yang diidentifikasi hanya pada bagian daun, tanpa menggunakan bagian tubuh lain, seperti akar, batang, atau buah sebagai masukan.

1.4 Tujuan Penelitian

Tujuan penelitian ini adalah merancang sistem klasifikasi penyakit daun tanaman kacang tanah menggunakan metode *Multiclass SVM* dengan pendekatan DAGSVM sebagai klasifikasinya dan ciri hasil ekstraksi tekstur GLCM dan ciri hasil ekstraksi warna HSV sebagai masukannya serta mengetahui performa dari sistem klasifikasi penyakit daun tanaman kacang tanah yang telah dibangun.

1.5 Manfaat Penelitian

Penelitian ini bermanfaat bagi petani dan dinas pertanian terkait untuk dapat dengan mudah mengetahui informasi jenis penyakit yang menyerang tanaman kacang tanah melalui daun sejak dini. Sehingga dapat lebih cepat dalam mengambil tindakan untuk melakukan pencegahan dan pengobatan agar tanaman kacang tanah tidak terjadi kegagalan panen dan menyebabkan kerugian pihak-pihak yang bersangkutan.

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian tentang klasifikasi penyakit daun tanaman tomat Dalam penelitian ini dilakukan tiga tahapan dalam pemrosesan gambar, pertama segmentasi menggunakan metode *color thresholding*. Kedua adalah ekstraksi fitur menggunakan *Gray Level Co-occurrence Matrices* (GLCM). Matriks GLCM yang digunakan dibuat dalam empat orientasi khusus yaitu 0° , 45° , 90° dan 135° . Ketiga, merupakan tahapan terakhir yaitu klasifikasi menggunakan metode *Support Vector Machine* (SVM), metode ini digunakan karena kekokohan dan optimalitasnya. Hasil dari penelitian deteksi penyakit daun tomat yang terdiri dari 4 kelas berbeda yaitu *bacterial spot*, *early blight*, *healthy* dan *spodermite* secara keseluruhan adalah 98,3% dengan validasi silang 10 kali lipat (Din, dkk, 2018).

Penelitian tentang klasifikasi penyakit pada daun tebu. Ekstraksi tekstur yang digunakan adalah metode GLCM, ekstraksi warna yang digunakan yaitu ruang warna $L^*a^*b^*$ dan metode klasifikasi yang digunakan yaitu metode *Support Vector Machine* (SVM). Dilakukan pengujian yaitu menguji sistem dengan ekstraksi fitur tekstur menghasilkan akurasi 33,33%, ketika menggunakan ekstraksi fitur warna menghasilkan akurasi 63,33%. Warna adalah fitur khusus untuk klasifikasi penyakit daun tebu, ketika dikombinasikan dengan ekstraksi fitur tekstur menghasilkan akurasi 80% (Ratnasari, dkk, 2014).

Penelitian untuk pengembangan metode klasifikasi *Support Vector Machine* (SVM) telah dilakukan untuk mengklasifikasikan penyakit daun yang disebabkan oleh jamur, bakteri, virus, dll seperti *Alternaria*, *Alternata*, *Anthracnose*, *Bacterial Blight* dan *Cercospora Leaf Spot*. Metode pengembangan SVM yang digunakan adalah metode *Multiclass-SVM* (M-SVM). Metode M-SVM dilakukan dengan membandingkan tiga kernel, yaitu *linier kernel*, *RBF kernel* dan *polynomial kernel*. Akurasi untuk kernel yang berbeda menekankan pada penyebaran vektor ruang. Metode *Multiclass-SVM* menghasilkan akurasi 96,7742% untuk *linier kernel* (Kulinavar, dkk, 2017).

Penelitian mengenai klasifikasi menggunakan metode M-SVM dengan menggunakan data citra preparat darah, yaitu kelas pertama *Falciparum Throozoit*, kelas kedua *Falciparum Schizont*, kelas ketiga adalah *Falciparum Gametocyt*, kelas keempat adalah *Vivax Schizont* dan kelas kelima adalah *Vivax Gametocyt*. Metode klasifikasi yang digunakan adalah *Multiclass SVM* dengan strategi *one-against-one* (OAO). Dari hasil

penelitian menunjukkan bahwa metode SVM OAO mampu mengklasifikasikan jenis parasit yang menyebabkan malaria, yaitu 95.55% untuk *falciparum thropozit*, 93.48% untuk *falciparum schizont*, 91.11% untuk *falciparum gametocyte*, 92.22% untuk *vivax schizont* dan 85% untuk *vivax gametocyte* (Permata, dkk, 2013).

Penelitian lain tentang metode klasifikasi, yaitu untuk klasifikasi data *electrocardiogram beat* dengan menggunakan metode *directed acyclic graph SVM* (DAGSVM). Pengujian dilakukan dengan menggunakan tiga jenis kernel, yaitu *linear*, *polynomial*, dan RBF. Dari hasil penelitian menunjukkan bahwa metode DAGSVM dengan kernel RBF menghasilkan rata-rata akurasi terbaik yaitu 97,71% dibandingkan dengan dua kernel lainnya yaitu kernel linear dengan rata-rata akurasi 92,08% dan kernel *polynomial* yaitu 95,62%. Selain itu hasil dari klasifikasi DAGSVM dengan dua jenis klasifikasi lain, yaitu KNN dan ANN. DAGSVM menghasilkan rata-rata akurasi 98,96%, KNN 95,83% dan ANN 96,66%. Sehingga diharapkan dengan menggunakan M-SVM dengan pendekatan DAGSVM dapat memberikan hasil akurasi klasifikasi yang akurat (Saini, dkk, 2014).

Penelitian klasifikasi motif tekstil dengan menggunakan metode *multiclass SVM one-against-all* (OAA), *one-against-one* (OAO) dan *directed acyclic graph support vector machine* (DAGSVM). Motif tekstil yang digunakan adalah citra bunga-bunga, polkadot dan kotak-kotak. Hasil dari penelitian berdasarkan kelompok motif diperoleh untuk motif kotak akurasi sebesar 78%, motif polkadot akurasi sebesar 65% dan untuk motif bunga-bunga akurasi sebesar 63%. Berdasarkan strategi *multiclass SVM* yang digunakan terhadap klasifikasi menunjukkan bahwa strategi DAGSVM memberikan hasil akurasi lebih baik bila dibandingkan dengan strategi OAA dan OAO, yaitu sebesar 78% (Ramadhani, dkk, 2020).

Penjelasan secara lengkap mengenai beberapa penelitian yang terkait akan ditunjukkan pada Tabel 2.1.

Tabel 2.1 Penelitian yang relevan

No.	Judul	Peneliti	Objek	Metode	Hasil
1.	<i>Identification of Disease in Tomato Plants' Leaf using Image Segmentation and SVM</i>	(Din, dkk, 2018)	Dataset citra daun tomat	Pada penelitian ini dilakukan segmentasi menggunakan metode <i>color thresholding</i> , ekstraksi fitur menggunakan metode GLCM dan klasifikasi menggunakan metode SVM.	Hasil dari penelitian ini yaitu mampu mendeteksi penyakit daun tanaman tomat dengan 4 kelas yang berbeda dengan akurasi 98,3% dengan validasi silang 10 kali lipat.
2.	<i>Sugarcane Leaf Disease Detection and Severity Estimation Based on Segmented Spots Image</i>	(Ratnasari, dkk, 2014)	Dataset citra daun tebu	Metode yang digunakan, yaitu ekstraksi warna menggunakan ruang warna $L^*a^*b^*$, ekstraksi tekstur menggunakan metode GLCM dan klasifikais menggunakan metode <i>Support Vector Machine</i> (SVM).	Pada penelitian ini dilakukan pengujian sistem dengan menggunakan ekstraksi tekstur dan ekstraksi warna dapat meningkatkan akurasi dengan hasil 80% dibandingkan hanya menggunakan ekstraksi

					warna saja atau ekstraksi tekstur saja.
3.	<i>Classification of Leaf Disease Based on Multiclass SVM Classifier</i>	(Kulinavar, dkk, 2017)	Dataset citra daun <i>altenaria</i> , <i>alternata</i> , <i>anthracnose</i> , <i>bacterial blight</i> dan <i>cercospora leaf spot</i>	Metode yang digunakan yaitu menggunakan pengembangan dari metode SVM, yaitu <i>multiclass SVM</i> dengan membandingkan tiga kernel, yaitu <i>linier kernel</i> , <i>RBF kernel</i> , <i>polynomial kernel</i> .	Hasil penelitian terbaik menggunakan metode <i>multiclass SVM</i> dengan <i>linier kernel</i> menghasilkan akurasi yaitu 96,7742%.
4.	Klasifikasi Jenis dan Fase Parasit Malaria Plasmodium Falciparum dan Plasmodium Vivax dalam Sel Darah Merah menggunakan Support Vector Machine One-Against-One	(Permata, dkk, 2013)	Dataset citra preparat darah berbagai jenis parasit malaria.	Metode klasifikasi yang digunakan adalah <i>multiclass SVM</i> dengan pendekatan <i>one-against-one</i> (OAO).	Hasil dari penelitian dengan menggunakan <i>multiclass SVM</i> dengan pendekatan OAO sebagai metode klasifikasi memberikan hasil akurasi yang baik untuk setiap kelasnya., yaitu 95.55% untuk <i>falciparum thropozit</i> ,

					93.48% untuk <i>falciparum schizont</i> , 91.11% untuk <i>falciparum gametocyte</i> , 92.22% untuk <i>vivax schizont</i> dan 85% untuk <i>vivax gametocyte</i> .
5.	<i>Electrocardiogram Beat Classification using Empirical Mode Decomposition and Multiclass Directed Acyclic Graph Support Vector Machine</i>	(Saini, dkk, 2014)	Dataset citra <i>electrocardiogram beat</i>	Metode yang digunakan untuk klasifikasi yaitu <i>multiclass SVM DAGSVM</i> dengan melakukan perbandingan tiga jenis kernel yaitu <i>linear, polynomial</i> dan <i>RBF</i> . Selain itu membandingkan hasil klasifikasi <i>DAGSVM</i> dengan <i>K-NN</i> dan <i>ANN</i> .	Hasil penelitian menunjukkan bahwa metode <i>multiclass SVM DAGSVM</i> dengan menggunakan kernel <i>RBF</i> memberikan hasil akurasi terbaik yaitu 97,71% dibandingkan dengan dua kernel lainnya, yaitu <i>linear</i> 92,08% dan <i>polynomial</i> 95,62%. Hasil perbandingan metode <i>DAGSVM</i> dengan <i>K-</i>

					NN dan ANN, yaitu DAGSVM 98,96%, K-NN 95,83% dan ANN 96,6%.
6.	Klasifikasi Otomatis Motif Tekstil menggunakan <i>Support Vector Machine</i> Multi Kelas	(Ramadhani, dkk, 2020)	Dataset citra motif tekstil, yaitu bunga-bunga, kotak-kotak dan polkadot	Metode klasifikasi yang digunakan adalah multi kelas <i>support vector machine</i> dengan strategi <i>one-against-all</i> (OAA), <i>one-against-one</i> (OAO) dan <i>directed scyclic graph</i> (DAGSVM).	Hasil dari penelitian bahwa klasifikasi motif tekstil menggunakan metode <i>multiclass</i> SVM dengan strategi DAGSVM memberikan hasil akurasi yang lebih baik bila dibandingkan dengan menggunakan strategi OAA dan OAO.

2.2 Tanaman Kacang Tanah

2.2.1 Morfologi Tanaman Kacang Tanah

Tanaman kacang tanah (*Arachis hypogaea L.*) merupakan tanaman leguminosa yang cukup penting di Indonesia. Kacang tanah merupakan tanaman yang paling banyak ditanam setelah padi, jagung dan kacang kedelai, biasanya ditanam untuk tanaman tumpang sari. Jenis kacang-kacangan ini memiliki tekstur kulit yang cokelat tipis dan bila kulitnya dilepas maka akan terlihat kacang yang berwarna putih dan memiliki rasa yang manis. Tanaman kacang tanah berbentuk tegak atau menjalar, dengan tinggi umumnya yaitu 15-70 cm. Sistem perakaran pada kacang tanah yaitu dengan akar tunggang dan akar lakteral yang berkembang dengan baik. Sistem perbatangan yaitu berseling (*alternate*), *sequential* tidak beraturan dengan bunga pada batang utama (Trustinah, 2015). Daun-daun pada cabang utama berjumlah empat daun dengan dua daun berada di tempat yang berlawanan. Panjang daun mencapai 3-4 cm dengan lebar 2-3 cm dan panjang petiole 3-7 cm.

Biji pada kacang tanah memiliki beragam warna, bentuk dan ukuran. Berdasarkan warna biji kacang tanah terdiri dari warna putih, agak putih, coklat sangat pucat, coklat pucat, coklat terang, coklat, coklat gelap, rose, salmon, merah terang, merah, merah gelap, merah keunguan, ungu cerah, ungu gelap, ungu sangat tua/ kehitaman. Sedangkan berdasarkan ukuran kacang tanah dibedakan menjadi kacang tanah biji kecil, kacang tanah biji sedang, dan kacang tanah biji besar (Trustinah, 2015).

2.2.2 Manfaat Kacang Tanah

Manfaat kacang tanah adalah sebagai berikut :

- 1) Biji kacang tanah dapat digunakan sebagai bahan olahan makanan untuk dikonsumsi manusia, seperti sebagai camilan, bahan masakan, selai, permen, dll.
- 2) Daun hasil panen dari kacang tanah dapat digunakan sebagai makanan ternak dan digunakan sebagai pupuk hijau.
- 3) Biji kacang tanah dapat diolah menjadi minyak goreng.
- 4) Kacang tanah mengandung zat besi yang sangat baik untuk produksi sel darah merah dalam tubuh.
- 5) Kalsium dalam kacang tanah bisa membantu memelihara pertumbuhan massa tulang sehingga menjadi lebih kuat.

2.2.3 Penyakit Daun Tanaman Kacang Tanah

Berikut adalah penyakit yang menyerang daun tanaman kacang tanah yang disebabkan oleh jamur (Hardaningsih & Sumartini, 2015) :

1) Bercak Daun

Penyakit bercak daun disebabkan oleh jamur *cercospora arachidicola* atau yang biasa disebut dengan penyakit bercak daun awal. Penyakit ini muncul pada awal pertumbuhan, yakni mulai pada umur tiga minggu. Gejala bercak daun awal berupa bercak-bercak berbentuk bulat yang terkadang tidak teratur dengan diameter 1-10 mm, berwarna coklat tua atau coklat kemerahan sampai hitam pada permukaan atas daun. Penyakit bercak daun pada tanaman kacang tanah ditunjukkan pada Gambar 2.1.



Gambar 2.1 Penyakit bercak daun

Sumber: *plantvillage.org*

2) Penyakit Karat

Penyakit karat pada daun tanaman kacang tanah disebabkan oleh jamur *Puccinia arachidis* Speg. Gejala penyakit karat adalah timbulnya pustul berwarna oranye sampai kecoklatan yang merupakan uredium pada permukaan atas daun atau bawah daun. Ukuran dari uredium yaitu 0,3 sampai 1 mm. Daun-daun yang terserang penyakit karat pada kacang tanah akan lebih tahan lama tinggal pada tanaman kacang tanah meskipun telah kering. Penyakit karat pada daun tanaman kacang tanah ditunjukkan pada Gambar 2.2.



Gambar 2.2 Penyakit karat daun tanaman kacang tanah

Sumber: *plantvillage.org*

3) Bercak Mata

Penyakit bercak mata pada daun tanaman kacang tanah memiliki gejala berupa bercak-bercak coklat tidak teratur dengan diameter kira-kira 2-4 mm yang dibatasi oleh garis yang tidak begitu jelas dan terputus-putus berwarna coklat sehingga mirip dengan mata. Penyebab penyakit bercak mata adalah jamur yang mirip *Helminthosporium sp.*, yaitu mempunyai konidia berbentuk silinder berwarna gelap, bersel 3-4 dengan ujung meruncing dan berwarna lain. Penyakit bercak mata pada daun tanaman kacang tanah ditunjukkan pada Gambar 2.3.



Gambar 2.3 Penyakit bercak mata daun tanaman kacang tanah

Sumber : Hardaningsih & Sumartini (2015)

2.3 Pengertian Citra Digital

Citra digital merupakan citra yang dapat diolah menggunakan komputer. Citra digital merupakan sebuah larik (*array*) yang berisi nilai-nilai real maupun kompleks yang dipresentasikan dengan deretan bit tertentu. Suatu citra dapat didefinisikan sebagai fungsi $f(x,y)$ berukuran N baris dan M kolom, dengan x dan y adalah koordinat spasial, amplitudo f di titik kordinat (x,y) dinamakan intensitas atau tingkat keabuan dari citra pada titik tersebut. Apabila nilai x,y dan nilai amplitudo f secara keseluruhan berhingga (*finite*) dan bernilai diskrit maka dikatakan bahwa citra tersebut adalah citra.

2.4 Pengolahan Citra Digital

Pengolahan citra digital merupakan bidang ilmu yang mempelajari bagaimana citra dibentuk, diolah dan dianalisis sehingga memberikan informasi yang dapat dipahami oleh manusia. Dalam proses pengolahan citra *input* berupa citra, sedangkan *output* nya adalah citra hasil dari pengolahan. Pengolahan citra adalah pemrosesan citra dengan maksud untuk mendapatkan kualitas citra yang diinginkan.

Operasi-operasi yang dilakukan dalam pengolahan citra terdiri dari beberapa jenis, antara lain :

1) Perbaikan kualitas citra (*image enhancement*)

Operasi ini bertujuan untuk memperbaiki kualitas citra dengan memanipulasi parameter citra, sehingga ciri-ciri khusus yang terdapat di dalam citra lebih ditonjolkan. Beberapa contoh dalam operasi perbaikan kualitas citra adalah perbaikan kontras gelap/terang, perbaikan tepian objek dan penajaman citra (*sharpening*).

2) Pemugaran citra (*image restoration*)

Operasi pemugaran citra yaitu bertujuan untuk menghilangkan atau meminimumkan cacat pada citra. Tujuan dari pemugaran citra sama dengan operasi perbaikan citra. Bedanya pada pemugaran citra penyebab degradasi gambar dapat diketahui. Beberapa contoh dalam operasi pemugaran citra adalah penghilangan kesamaan (*deblurring*) dan penghilang derau (*noise*).

3) Pemampatan citra (*image compression*)

Operasi pemampatan citra bertujuan untuk mempresentasikan citra dalam bentuk yang lebih kompak sehingga keperluan memori lebih sedikit namun tetap mempertahankan kualitas dari gambar. Contoh dari pemampatan citra adalah metode .JPEG.

4) Segmentasi citra (*image segmentation*)

Operasi segmentasi citra bertujuan untuk membagi suatu citra ke dalam beberapa segmen dengan kriteria tertentu.

5) Analisis citra (*image analysis*)

Operasi analisis citra bertujuan untuk menghitung besaran kuantitatif dari citra masukan untuk mendapatkan informasi dari citra tersebut. Beberapa contoh dalam analisis citra adalah pendekatan tepi objek (*edge detection*), ekstraksi batas (*boundary*) dan representasi daerah (*region*).

6) Rekonstruksi citra (*image reconstruction*)

Operasi dari rekonstruksi citra bertujuan untuk membentuk ulang objek dari beberapa hasil proyeksi. Operasi rekonstruksi citra banyak digunakan dalam bidang medis. Contohnya adalah beberapa foto *rontgen* dengan sinar X yang digunakan untuk membentuk ulang gambar organ tubuh. Contoh lain yaitu untuk rekonstruksi foto janin hasil USG.

2.5 Ruang Warna

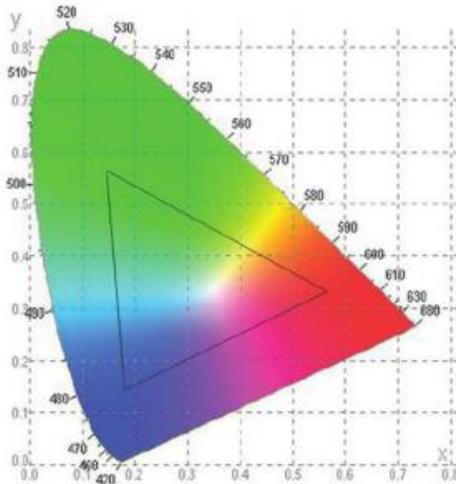
Ruang warna yang biasa disebut juga dengan model warna atau sistem warna merupakan suatu spesifikasi sistem koordinat dan suatu subruang dalam sistem dengan setiap warna dinyatakan dengan satu titik di dalamnya. Terdapat beberapa ruang warna, antara lain RGB, $L^*a^*b^*$ dan HSV.

2.5.1 Ruang Warna RGB

Ruang warna RGB menggunakan tiga komponen dasar, yaitu merah (R), Hijau (G) dan Biru (B). Setiap piksel terdiri dari tiga komponen, yaitu R, G dan B. RGB banyak diterapkan pada monitor CRT dan banyak pada sistem grafika komputer. Ruang warna RGB banyak digunakan karena kemudahan dalam perancangan *hardware*, namun ruang warna ini tidak bagus untuk digunakan dalam beberapa aplikasi. Hal ini dikarenakan untuk mendapatkan warna alamiah seperti hijau dengan menggunakan RGB akan menjadi sangat kompleks, karena komponen dapat berpasangan dengan R dan B.

2.5.2 Ruang Warna $L^*a^*b^*$

CIE menjadi sistem warna standar sehingga ketika warna ditentukan oleh sistem ini berarti dapat digunakan dimana saja terhadap perangkat printer, scanner atau monitor dan salah satu sistem CIE yang paling berguna adalah CIELAB. CIELAB adalah nama lain dari CIE $L^*a^*b^*$. CIE $L^*a^*b^*$ memiliki tiga komponen L^* berkorelasi dengan kecerahan, a^* dengan kemerahan-kehijauan dan b^* dengan kekuningan-kebiruan. Pada diagram kromasitas CIE, setiap perpaduan x dan y menyatakan suatu warna. Namun, hanya warna berada dalam area ladam (tapal kuda) yang dapat 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. Diagram kromasitas CIE (*Commmision Internatiolle de L'Eclairage*) ditunjukkan pada Gambar 2.4.



Gambar 2.4 Diagram kromasitas CIE

Sumber : Kadir & Susanto (2013)

Persamaan yang digunakan untuk merubah ruang warna RGB menjadi $L^*a^*b^*$ adalah persamaan (2-1) sampai dengan (2-7) (Kadir & Susanto, 2013).

Transformasi RGB ke $L^*a^*b^*$ dimulai dengan melakukan perhitungan berikut :

$$X = 0,412453R + 0,357580G + 0,180423B \quad (2-1)$$

$$Y = 0,212671R + 0,715160G + 0,072169B \quad (2-2)$$

$$Z = 0,019334R + 0,119193G + 0,950227B \quad (2-3)$$

Selanjutnya $L^*a^*b^*$ didefinisikan sebagai berikut

$$L^* = 116f\left(\frac{Y}{Y_n}\right) - 16 \quad (2-4)$$

$$a^* = 500 \left[f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right] \quad (2-5)$$

$$b^* = 200 \left[f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right] \quad (2-6)$$

Dalam hal ini, $f(q)$ dihitung seperti berikut

$$f(q) = \begin{cases} q^{\frac{1}{3}}, & \text{jika } q > 0,008856 \\ 7,787q + \frac{16}{116}, & \text{untuk yang lain} \end{cases} \quad (2-7)$$

X_n, Y_n, Z_n diperoleh melalui $R=G=B=1$ dengan jangkauan R,G,B berupa $[0,1]$.

2.5.3 Ruang Warna HSV

HSV pertama kali diperkenalkan oleh A.R. Smith pada tahun 1978. Model warna HSV terdiri dari H berasal dari kata “hue”, S berasal dari kata “saturation” dan V berasal dari kata “value”. *Hue* menyatakan warna sebenarnya seperti merah, violet dan kuning. *Hue* digunakan untuk membedakan warna-warna dan menentukan kemerahan, kehijauan, dsb

dari cahaya. *Hue* berasosiasi dengan panjang gelombang cahaya. *Saturation* menyatakan tingkat kemurnian suatu warna yang mengindikasikan seberapa banyak warna putih pada warna. *Value* merupakan kecerahan dari warna, dengan nilai 0% maka berwarna hitam dan nilai 100% maka warna akan semakin cerah.

Persamaan untuk mengubah dari ruang warna RGB ke HSV yang digunakan adalah persamaan (2-8) sampai (2-12) (Kadir & Susanto, 2013)

$$r = \frac{R}{R + G + B}, \quad g = \frac{G}{R + G + B}, \quad b = \frac{B}{R + G + B} \quad (2-8)$$

$$V = \max(r, g, b) \quad (2-9)$$

$$H = \begin{cases} 0 & \text{if } S = 0 \\ \frac{60 * (g - b)}{S * V} & \text{if } V = r \\ 60 * \left[2 + \frac{(b - r)}{S * V} \right] & \text{if } V = g \\ 60 * \left[4 + \frac{(r - g)}{S * V} \right] & \text{if } V = b \end{cases} \quad (2-10)$$

$$S = \begin{cases} 0 & \text{if } V = 0 \\ V - \frac{\min(r, g, b)}{V} & \text{if } V > 0 \end{cases} \quad (2-11)$$

$$H = H + 360 \quad \text{if } H < 0 \quad (2-12)$$

2.6 K-means

Metode pengelompokan K-means adalah metode yang paling populer karena sederhana dan mudah diimplementasikan sehingga banyak digunakan dalam berbagai bidang. Metode K-means merupakan metode proses pemodelan *unsupervised learning*. Metode K-means merupakan salah satu metode pengelompokan nonhirarki yang berusaha membagi data yang ada ke dalam beberapa kelompok. Kelompok yang terbentuk membentuk karakteristik yang sama antara satu dengan yang lainnya dan memiliki karakteristik yang berbeda dengan data yang ada pada kelompok lain. Langkah-langkah yang digunakan dalam proses metode K-means seperti pada uraian berikut :

1. Menentukan jumlah *cluster* yang ingin dibentuk.
2. Membangkitkan *centroid* sesuai dengan jumlah *cluster* secara *random*.
3. Menghitung jarak setiap data ke masing-masing *centroid* menggunakan perhitungan jarak terdekat. *Manhattan distance* dihitung menggunakan persamaan (2-13)

$$d_{ij} = \sum_{k=1}^n (x_{ik} - y_{jk}) \quad (2-13)$$

4. Setiap data memilih *centroid* yang terdekat, yang menunjukkan bahwa data tersebut berada dalam satu kelompok dengan *centroid* terdekat.
5. Menghitung rata-rata dari masing-masing data *cluster* untuk menghasilkan *centroid* baru.
6. Kembali ke step 3, apabila masih ada data yang berpindah *cluster* atau terjadi perubahan nilai *centroid*.

2.7 Ekstraksi Ciri

Ekstraksi ciri merupakan langkah penting dalam membangun klasifikasi dan bertujuan untuk mengekstrak informasi yang relevan yang menjadi ciri dari setiap kelas. Ekstraksi ciri pada citra merupakan proses pengindeksan suatu database citra dengan isinya. Secara matematis, setiap ekstraksi ciri merupakan *encode* dari vektor n dimensi yang disebut dengan vektor ciri. Tujuan dari ekstraksi ciri adalah melakukan perhitungan dan perbandingan yang bisa digunakan untuk mengklasifikasikan ciri-ciri yang dimiliki oleh suatu citra. Ekstraksi ciri memiliki peran yang sangat penting, karena semakin bagus ekstraksi cirinya, maka semakin tinggi tingkat akurasi. Terdapat bermacam-macam ekstraksi ciri berdasarkan tekstur, bentuk dan warna.

2.7.1 Gray Level Co-occurrence Matrix (GLCM)

Metode GLCM merupakan salah satu metode yang digunakan untuk ekstraksi ciri tekstur yang termasuk dalam metode statistik. Metode statistik adalah metode yang menganalisa distribusi spasial pada nilai keabuan atau turunan dari kumpulan statistik. Metode statistik terdiri dari ekstraksi ciri orde pertama dan ekstraksi ciri orde kedua. Ekstraksi ciri orde pertama yaitu perhitungan statistik berdasarkan nilai piksel citra asli dan tidak memperhatikan piksel ketetanggaan, sedangkan ekstraksi ciri statistik orde kedua dilakukan dengan matriks kookurensi, yaitu suatu matriks yang mempresentasikan hubungan ketetanggaan antar piksel dalam citra pada berbagai jarak dan orientasi sudut tertentu.

Metode GLCM merupakan ekstraksi ciri orde kedua, yaitu dengan membentuk matriks kookurensi dari data citra, yang kemudian dilanjutkan dengan menentukan ciri sebagai fungsi dari matriks tersebut. Pada metode GLCM jarak (d) dinyatakan dalam piksel dan orientasi sudut (θ) dinyatakan dalam derajat. Orientasi dibentuk dalam empat arah sudut

dengan interval sudut 0° , 45° , 90° dan 135° . Sedangkan jarak antar piksel biasanya ditetapkan sebesar 1 piksel, 2 piksel, 3 piksel dan seterusnya. Langkah-langkah untuk ekstraksi ciri tekstur dengan menggunakan metode GLCM sebagai berikut :

1. Membentuk area kerja matriks

Matriks asal 4x4 yang digunakan sebagai contoh perhitungan dengan menggunakan metode GLCM diperlihatkan pada Gambar 2.5.

$$\begin{bmatrix} 0 & 0 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 2 & 2 & 2 \\ 2 & 2 & 3 & 3 \end{bmatrix}$$

Gambar 2.5 Matriks asal

Sumber : Kadir & Susanto (2013)

Karena matriks asal memiliki empat aras keabuan, maka jumlah nilai piksel tetangga dan nilai piksel referensi pada area kerja matriks berjumlah empat, seperti yang dijelaskan pada Tabel 2.2.

Tabel 2.2 Area kerja matriks

Nilai Piksel Referensi \ Nilai Piksel Tetangga	0	1	2	3
0	0,0	0,1	0,2	0,3
1	1,0	1,1	1,2	1,3
2	2,0	2,1	2,2	2,3
3	3,0	3,1	3,2	3,3

Sumber: Kadir & Susanto (2013)

2. Membentuk matriks kookurensi

Menghitung nilai dari matriks dengan mengisikan jumlah hubungan spasial, misal hubungan spasial yang digunakan adalah $d=1$ dan $\theta = 0^\circ$. Hasil dari matriks kookurensi diperlihatkan pada Gambar 2.6.

0	0	1	1	2	2	1	0
0	0	1	1	0	2	0	0
0	2	1	1	0	0	3	1
2	2	3	3	0	0	0	0

Gambar 2.6 Pembentukan matriks kookurensi dari matriks asal

3. Membuat matriks transpose

Matriks kookurensi yang telah didapat kemudian dilakukan transpose, yaitu mengubah matriks baris menjadi kolom. Hasil dari pembentukan matriks transpose diperlihatkan pada Gambar 2.7.

2	0	0	0
2	2	0	0
1	0	3	0
0	0	1	0

Gambar 2.7 Pembentukan matriks transpose

4. Membuat matriks simetris

Proses selanjutnya yaitu membuat matriks simetris dengan cara menjumlahkan matriks kookurensi dengan matriks transposenya untuk menjadikan simetris terhadap sumbu diagonal. Hasil dari pembentukan matriks simetris diperlihatkan pada Gambar 2.8.

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

Gambar 2.8 GLCM Simetris

Sumber : Kadir & Susanto (2013)

5. Membuat matriks normalisasi

Matriks yang sudah simetris selanjutnya dinormalisasi, yaitu dengan cara nilai elemen-elemen untuk masing-masing sel dibagi dengan jumlah seluruh elemen spasial. Matriks yang telah ternormalisasi diperlihatkan pada Gambar 2.9

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

Gambar 2.9 GLCM normalisasi

Setelah memperoleh matriks kookurensi tersebut, kita dapat menghitung ciri statistik orde dua yang mempresentasikan ciri yang diamati. Jenis ciri tekstural yang dapat diekstraksi dari matriks kookurensi, yaitu *angular second moment*, *contrast*, *inverse*

difference moment, correlation, entropy, variance, sum average, sum entropy, sum variance, difference entropy, dan difference variance (Prastyaningsih, 2016).

Angular second moment yaitu ukuran homogenitas dari suatu citra. *Angular second moment* dihitung dengan menggunakan persamaan (2-14).

$$ASM = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} P(i, j)^2 \quad (2-14)$$

Contrast merupakan ukuran ragam intensitas keberadaan suatu citra atau ukuran penyebaran elemen keabuan dalam suatu citra. *Contrast* dihitung dengan menggunakan persamaan (2-15).

$$Contrast = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - j)^2 P(i, j) \quad (2-15)$$

Inverse difference moment digunakan untuk mengukur homogenitas. Homogenitas yang dimaksud adalah homogenitas lokal pada gambar yang diamati. IDM dihitung dengan menggunakan persamaan (2-16).

$$IDM = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \frac{P(i, j)}{1 + (i - j)^2} \quad (2-16)$$

Correlation merupakan ukuran ketergantungan linear atau nilai aras keabuan dalam citra. *Correlation* menghitung korelasi antara satu piksel dengan piksel lainnya. *Correlation* dihitung dengan menggunakan persamaan (2-17).

$$Correlation = \sum_{i=0}^{N_g} \sum_{j=0}^{N_g} \frac{(i \times j)P(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (2-17)$$

Entropy digunakan untuk mengukur ketidakteraturan piksel pada citra. *Entropy* dihitung dengan menggunakan persamaan (2-18).

$$Entropy = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \log[p(i, j)] \quad (2-18)$$

Variance digunakan untuk mengukur penyebaran (berhubungan dengan *mean*) dari distribusi tingkat keabuan. *Variance* dihitung dengan menggunakan persamaan (2-19).

$$Variance = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 P(i, j) \quad (2-19)$$

Sum average digunakan untuk mengukur rata-rata distribusi jumlah tingkat keabuan pada citra. *Sum average* dihitung dengan menggunakan persamaan (2-20)

$$\text{Sum Average} = \sum_{i=2}^{2N_g} ip_{x+y}(i) \quad (2-20)$$

Sum entropy digunakan untuk mengukur *noise* yang berkaitan dengan distribusi *level* keabuan pada citra. *Sum entropy* dihitung dengan menggunakan persamaan (2-21).

$$\text{Sum Entropy} = - \sum_{i=2}^{2N_g} p_{x+y}(i) \log\{p_{x+y}(i)\} \quad (2-21)$$

Sum variance digunakan untuk mengukur penyebaran (berhubungan dengan *mean*) pada distribusi jumlah keabuan pada citra. *Sum variance* dihitung dengan menggunakan persamaan (2-22).

$$\text{Sum Variance} = \sum_{i=2}^{2N_g} \left(i - \left[\sum_{i=2}^{2N_g} ip_{x+y}(i) \right] \right)^2 \quad (2-22)$$

Difference entropy digunakan untuk mengukur *noise* yang berkaitan dengan distribusi perbedaan tingkat keabuan pada citra. *Difference entropy* dihitung dengan menggunakan persamaan (2-23).

$$\text{Difference Entropy} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log\{p_{x-y}(i)\} \quad (2-23)$$

Difference variance digunakan untuk mengukur penyebaran (sehubungan dengan *mean*) pada distribusi perbedaan keabuan pada citra. *Difference variance* dihitung dengan menggunakan persamaan (2-24).

$$\text{Difference Variance} = \sum_{i=2}^{2N_g} \left(i - \left[\sum_{i=2}^{2N_g} ip_{x-y}(i) \right] \right)^2 \quad (2-24)$$

Dimana N_g adalah jumlah level keabuan, $P(i, j)$ merupakan distribusi probabilitas bersama dari pasangan piksel dengan tingkat keabuan i dan tingkat keabuan j , μ adalah rata-rata nilai piksel dan σ adalah standar deviasi.

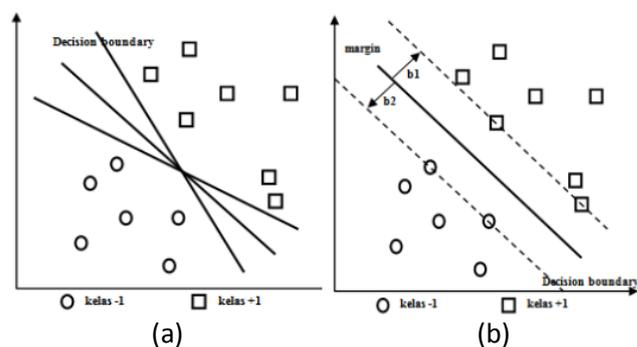
2.8 Klasifikasi

Klasifikasi merupakan proses untuk menemukan model atau fungsi yang menjelaskan atau membedakan konsep atau kelas data dengan tujuan untuk dapat memperkirakan kelas dari suatu objek. Tujuan dari klasifikasi adalah mengenali citra dengan cara mengklasifikasikan ciri-ciri yang dimiliki. Pada proses klasifikasi terdapat dua fase, yaitu

fase pelatihan dan fase pengujian. Fase pelatihan yaitu sebagian data yang telah diketahui kelas datanya digunakan untuk membentuk model perkiraan. Sedangkan untuk fase pengujian model yang sudah terbentuk diuji dengan sebagian data lainnya untuk mengetahui akurasi dari model tersebut. Klasifikasi dapat dilakukan menggunakan berbagai metode pengklasifikasian. Banyak algoritma yang dapat digunakan untuk klasifikasi, seperti *decision tree learning*, *nearest neighbor*, *naive bayes classification*, *neural network*, *support vector machine*, dan sebagainya.

2.9 Support Vector Machine (SVM)

Metode SVM secara sederhana, yaitu usaha yang dilakukan untuk mencari *hyperplane* terbaik yang digunakan untuk pemisah dua buah kelas data pada *input space*. Gambar 2.10 (a) memperlihatkan bahwa metode SVM menggunakan prinsip *binary classifier* yang hanya mampu mengklasifikasikan ke dalam dua kelas yang berbeda, yaitu +1 dan -1. *Hyperplane* terbaik adalah yang berada di tengah antara objek dan dua kelas, yaitu kelas positif dan kelas negatif. Cara untuk mendapatkan *hyperplane* terbaik adalah dengan mengukur margin *hyperplane* dan mencari titik maksimalnya. *Margin* merupakan jarak antara *hyperplane* tersebut dengan data terdekat dari masing-masing kelas. Data terdekat disebut dengan *support vector*. Gambar 2(10) b memperlihatkan *hyperplane* dengan margin maksimal.



Gambar 2.10 Batas keputusan yang mungkin untuk set data

Sumber: Prasetyo (2014)

2.9.1 SVM Linear

Dalam menyelesaikan permasalahan klasifikasi menggunakan metode SVM secara linear diasumsikan terdapat dataset, yaitu $\{x_i, y_i\}$ dimana x_i merupakan atribut untuk data latih $x_i \in \{x_1, \dots, x_n\}$ dan $y_i \in \{+1, -1\}$ yang merupakan label kelas dari data x_i . Dalam metode SVM bidang *hyperplane* dikatakan baik, apabila tidak hanya dapat memisahkan data, tetapi juga dapat memiliki margin yang maksimal, data yang berada dekat dan di atas

hyperplane. Pertama yang harus dilakukan adalah mencari *hyperplane* fungsi $f(w, b) = x_i \cdot w + b$ yang dipisahkan menjadi kelompok positif dan negatif.

$$x_i \cdot w + b \geq 1 \text{ untuk } y_i = 1 \quad (2-25)$$

$$x_i \cdot w + b \leq -1 \text{ untuk } y_i = -1 \quad (2-26)$$

Dimana x_i merupakan data ke- i , w adalah bobot *support vector* yang tegak lurus terhadap *hyperplane*, b adalah nilai bias, dan y_i adalah kelas data ke- i .

Sehingga didapatkan Persamaan (2-27) sebagai berikut :

$$y_i(x_i \cdot w + b) - 1 \geq 0 \text{ untuk } i = 1, \dots, n \quad (2-27)$$

Dimana n adalah jumlah data.

Hyperplane terbaik adalah *hyperplane* yang terletak di tengah-tengah antara dua set objek dari dua kelas. Mencari *hyperplane* terbaik yang ekuivalen dengan cara membuat maksimal margin atau jarak antara dua set obyek dari kelas yang berbeda. Jika $w \cdot x_1 + b = 1$ adalah *hyperplane* dari kelas +1 atau bisa disebut juga sebagai H_1 dan $w \cdot x_2 + b = -1$ atau bisa disebut juga sebagai H_2 . Sehingga margin antara kedua kelas dapat dihitung dengan cara mencari jarak antara kedua *hyperplane* dari dua kelas tersebut. Perhitungan *margin* dapat dihitung menggunakan Persamaan (2-28).

$$\text{Margin} = |d_{H_1} - d_{H_2}| = \frac{2}{\|w\|} \quad (2-28)$$

Dimana d_{H_1} adalah jarak *hyperplane* pendukung kelas +1 dan d_{H_2} adalah jarak *hyperplane* pendukung kelas -1.

Selanjutnya untuk menentukan *hyperplane* pemisah kedua kelas, maka *margin* perlu dimaksimalkan menggunakan Persamaan (2-29).

$$\text{Minimize } J_1[w] = \frac{1}{2} \|w\|^2 \quad (2-29)$$

dengan $y_i(x_i \cdot w + b) - 1 \geq 0, i = 1, \dots, n$

Dimana $\|w\|$ adalah vektor bobot w .

2.9.2 SVM NonLinear

Metode SVM nonlinear digunakan untuk menyelesaikan masalah-masalah yang bersifat non-linear. Konsep dari SVM nonlinear adalah memetakan data $x_k \rightarrow \phi x_k$ ke dalam *feature space* sehingga terdapat bidang pemisah yang dapat memisahkan data dengan kelasnya. Dalam menyelesaikan permasalahan non-linear yaitu dapat dengan memodifikasi menggunakan fungsi kernel yang didefinisikan sebagai *kernel trick*. *Kernel*

trick digunakan untuk memetakan fungsi kernel tanpa harus mengetahui wujud dari fungsi nonlinear. Perhitungan *kernel trick* dapat dihitung menggunakan Persamaan (2-30).

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (2-30)$$

Dimana $K(x_i, x_j)$ merupakan fungsi kernel, $\phi(x_i)$ merupakan transformasi data ke- i dan $\phi(x_j)$ merupakan transformasi data ke- j .

Selain menggunakan Persamaan (2-30) dapat digunakan model *quadratic problem* untuk mendapatkan *hyperplane* yang lebih optimal dengan menggunakan Persamaan (2-31).

$$\min \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n a_i \cdot y_i \cdot K(x_i, x_j) \quad (2-31)$$

Dimana a_i adalah *alpha* ke- i , y_i adalah kelas sampel data (positif (+1) dan negatif (-1) dan $K(x_i, x_j)$ merupakan fungsi kernel.

Nilai $K(x, y)$ adalah pemetaan fungsi linear pada fungsi kernel pada *feature space*. Fungsi keputusan klasifikasi optimal dihitung dengan menggunakan Persamaan (2-32).

$$f(x) = \sum_{i=1}^m a_i y_i K(x_i, x) + b \quad (2-32)$$

Terdapat beberapa fungsi kernel yang digunakan untuk menyelesaikan masalah pada SVM non linear dapat dilihat pada Persamaan (2-33) sampai (2-34) berikut ini (Prasetyo, 2014).

1. Fungsi Kernel Linear (2-33)

$$k(x, y) = x \cdot y$$

2. Fungsi Kernel Polinomial

$$k(x, y) = (1 + x \cdot y)^q, q = 1, 2, \dots, N \quad (2-34)$$

3. Fungsi Kernel RBF

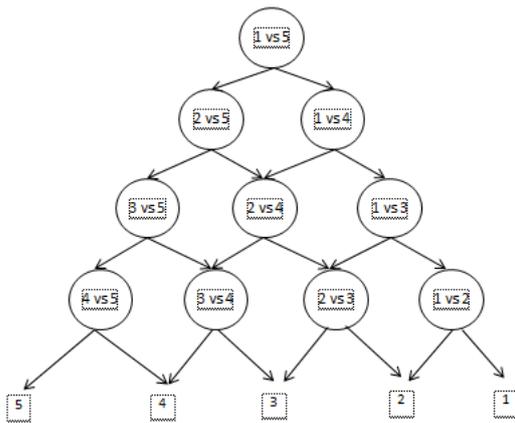
$$k(x, y) = \exp \frac{(-\|x - y\|^2)}{2\sigma^2} \quad (2-35)$$

2.9.3 Directed Acyclic Graph Support Vector Machine (DAGSVM)

Metode *Directed Acyclic Graph Support Vector Machine* (DAGSVM) merupakan salah satu pendekatan dari M-SVM. Dalam metode DAGSVM, pelatihan dilakukan dengan cara membangun $N(N-1)/2$ buah model klasifikasi SVM biner sama seperti metode *one-against-one*. Sedangkan pada tahapan pengujian, yaitu hanya $N-1$ kali. Hal inilah yang

menunjukkan keunggulan dari metode DAGSVM yaitu waktu yang dibutuhkan lebih sedikit bila dibandingkan dengan metode lain.

Pada metode DAGSVM terdapat sebuah *node* pada layer paling atas yang disebut dengan *root node*. Dua *node* berada pada layer kedua dan layer seterusnya. Setiap *node* merupakan model SVM biner dari kelas ke-*i* dan kelas ke-*j*. Saat melakukan pengujian dievaluasi dimulai dari *root node*, kemudian bergerak ke kiri atau ke kanan tergantung nilai dari *output* yang dihasilkan. Ilustrasi klasifikasi dengan metode DAGSVM diperlihatkan pada Gambar 2.11.



Gambar 2.11 Ilustrasi klasifikasi dengan metode DAGSVM

Sumber: Cholissodin (2014)

2.10 Evaluasi

Analisis bertujuan untuk memperoleh informasi dari hasil yang terdapat pada hasil klasifikasi. Dalam mengetahui kinerja dari model klasifikasi berupa akurasi digunakan *confusion matrix*. *Confusion matrix* adalah sebuah matriks yang menunjukkan nilai aktual dan nilai prediksi dari klasifikasi. Akurasi menghitung proporsi dari data uji yang diklasifikasikan dengan benar dari keseluruhan data uji. Akurasi di hitung dengan menggunakan Persamaan (2-36).

Dengan menggunakan *confusion matrix* selain dapat diketahui tingkat akurasi juga dapat diketahui nilai sensitivitas dan spesifisitas. Sensitivitas dapat didefinisikan sebagai nilai *true positive*. Sensitivitas merupakan kemampuan suatu *classifier* untuk menunjukkan hasil positif pada objek yang diamati. Sensitivitas memberi informasi seberapa baik sebuah *classifier* untuk mengidentifikasi hasil prediksi positif jika diberikan sampel aktual positif. Kemudian spesifisitas dapat didefinisikan sebagai nilai *true negative*. Sensitivitas merupakan kemampuan suatu *classifier* untuk menunjukkan hasil negatif pada objek yang

diamati. Spesifisitas hanya memberi informasi proporsi dari hasil prediksi negatif jika diberikan sampel aktual negatif. Sensitivitas dan spesifisitas masing-masing akan dihitung dengan menggunakan Persamaan (2-37) dan (2-38).

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (2-36)$$

$$\text{Sensitivitas} = \frac{TP}{TP + FN} \times 100\% \quad (2-37)$$

$$\text{Spesifisitas} = \frac{TN}{TN + FP} \times 100\% \quad (2-38)$$

Dimana:

- *True Positive* (TP) merupakan kasus positif yang diklasifikasikan secara benar dan hasilnya positif.
- *True Negative* (TN) merupakan kasus negatif yang diklasifikasikan secara benar dan hasilnya negatif.
- *False Positive* (FP) merupakan kasus dengan kelas negatif yang diklasifikasikan pada kelas negatif.
- *False Negative* (FN) merupakan kasus dengan kelas positif yang diklasifikasikan pada kelas negatif.

BAB III

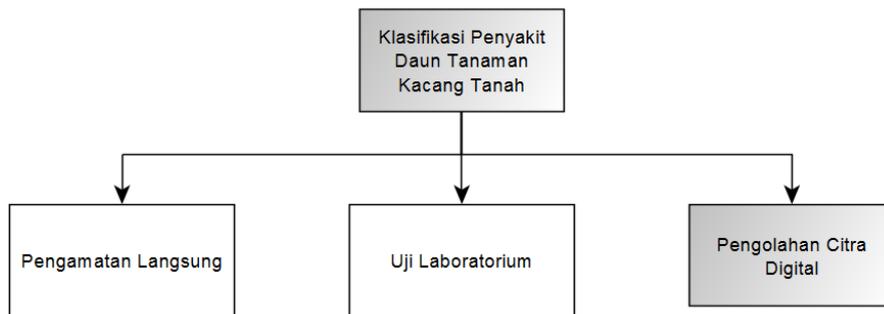
KERANGKA KONSEP PENELITIAN

3.1 Kerangka Teori Penelitian

Tanaman kacang tanah merupakan jenis tumbuhan dengan kandungan lemak tertinggi diantara semua jenis tanaman kacang. Produk olahan yang dihasilkan dari kacang tanah merupakan cara untuk menaikkan nilai jual disamping mendukung perluasan jenis makanan utama. Selain itu dapat digunakan untuk menambah harga jual ekspor dari kacang tanah, karena selama ini masih diekspor dengan bentuk kacang mentah. Produk olahan kacang tanah, yaitu kacang asin, minyak, pasta, tahu kacang tanah, tepung kacang tanah, kue kering (*cookies*) kacang tanah, biskuit kacang tanah, produksi cair (susu) kacang tanah.

Berdasarkan banyaknya hasil olahan yang berasal dari kacang tanah dan manfaat kacang tanah terhadap masyarakat, maka permintaan terhadap konsumsi kacang tanah terus bertambah. Beberapa upaya dilakukan untuk meningkatkan produktivitas kacang tanah serta meningkatkan kualitas hasil panen sesuai dengan kebutuhan masyarakat.

Cara tradisional masih banyak digunakan oleh petani untuk mengenali penyakit pada kacang tanah, khususnya pada daun. Cara tradisional yang digunakan adalah dengan mengamati bagian daun yang berpenyakit dengan mata terbuka. Hal ini mengakibatkan kurangnya akurasi identifikasi penyakit pada tanaman. Cara lain untuk mengetahui macam penyakit pada daun kacang tanah yaitu dengan uji lab dari daun yang berpenyakit. Uji lab ini dilakukan dengan cara mengambil sampel daun kacang tanah dengan terindikasi penyakit, kemudian akan diuji di laboratorium dengan cara mengisolasi patogen yang bersekutu dengan ciri penyakit pada sampel. Isolasi patogen dilakukan dengan metode penanaman jaringan. Sampel tanaman yang telah melewati beberapa proses, kemudian akan diinkubasi. Setelah diinkubasi 2-3 hari sampel tanaman akan diamati menggunakan mikroskop dan akan diidentifikasi jenis penyakit yang menyerang daun (Rahayu dan Sumartini, 2017). Cara uji laboratorium ini dianggap kurang efisien, karena membutuhkan waktu yang lama. Salah satu cara *modern* yang bisa digunakan adalah aplikasi dari pengolahan citra. Citra daun berpenyakit dapat digunakan dalam identifikasi untuk jenis penyakit. Aplikasi ini dapat membantu petani dan pihak pertanian untuk dengan cepat mengenali jenis penyakit yang muncul pada tanaman berdasarkan ciri penyakitnya. Gambar 3.1 metode yang bisa dipakai dalam klasifikasi penyakit daun kacang tanah.

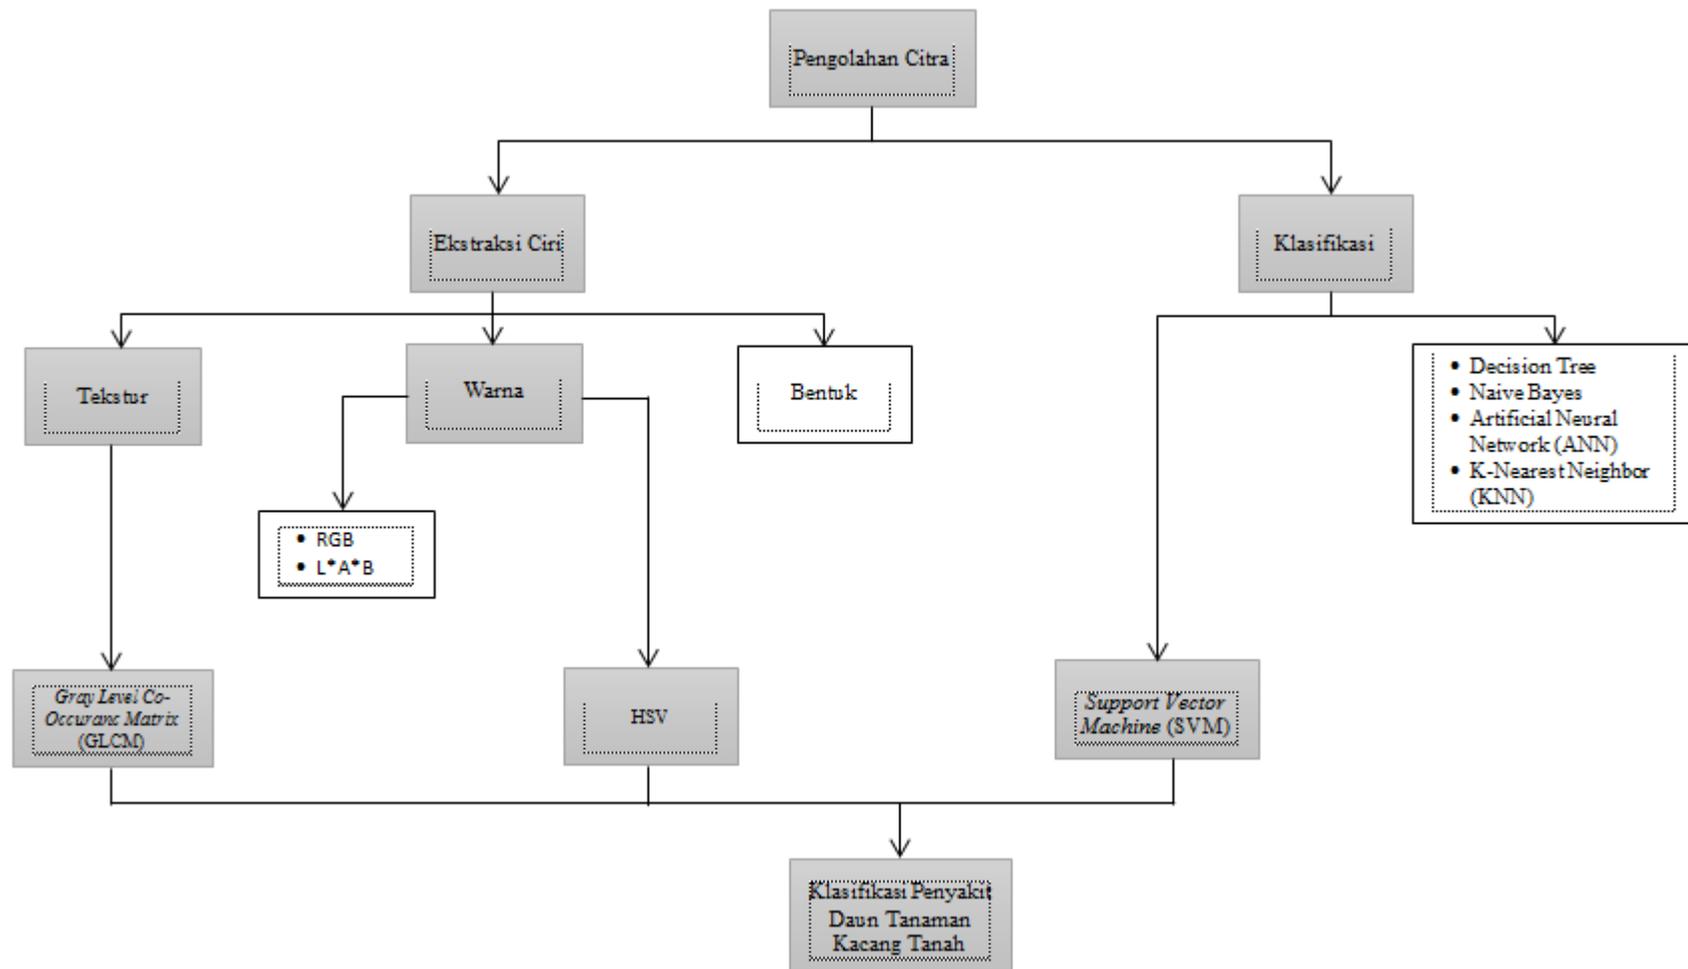


Gambar 3.1 Metode untuk klasifikasi penyakit daun kacang tanah

Keterangan :

 : Fokus Penelitian

Metode klasifikasi penyakit daun kacang tanah yang dapat digunakan, yaitu pengolahan citra yang merupakan salah satu dari pengembangan teknologi saat ini. Diharapkan dengan menggunakan metode pengolahan citra dengan masukan berupa citra daun dapat membantu petani dan petugas terkait untuk mengetahui jenis penyakit yang menyerang daun kacang tanah dengan cepat dan akurat. Kerangka teori penelitian pengolahan citra yang diterapkan untuk mengetahui jenis penyakit daun tanaman kacang tanah terdiri dari beberapa bagian yang dijelaskan dengan kerangka teori penelitian pada Gambar 3.2.



Gambar 3.2 Kerangka teori penelitian

 : Fokus Penelitian

Pada Gambar 3.2 menunjukkan beberapa konsep dalam ekstraksi ciri dan klasifikasi. Ekstraksi ciri merupakan proses untuk mengambil fitur dari citra yang hasilnya akan digunakan dalam proses berikutnya. *Gray Level Co-Occurrence Matrix* (GLCM) adalah metode dalam ekstraksi fitur tekstur. GLCM mempunyai karakteristik yaitu penggunaan orientasi dan jarak spasial untuk proses pengenalan ciri pada suatu citra. Metode GLCM dipilih sebagai ekstraksi ciri tekstur karena metode GLCM adalah algoritma yang sudah terbukti sebagai deskriptor tekstur efektif dan menghasilkan akurasi yang lebih baik dibandingkan dengan metode lainnya (Siqueira, dkk, 2013). Penggunaan GLCM untuk analisis tekstur sudah banyak dipakai pada banyak bidang dan terbukti memberikan hasil analisis tekstur yang baik. Selain ekstraksi fitur tekstur dipakai ekstraksi fitur warna dalam ruang warna HSV. HSV mengartikan warna pada *Hue* (warna sesungguhnya), *Saturation* (kemurnian dari warna) dan *Value* (kecerahan dari warna). Kelebihan dari ruang warna HSV yaitu terdiri dari warna-warna yang dapat ditangkap oleh penglihatan manusia.

Konsep klasifikasi adalah *training* pada f (target) yang mengklasifikasikan setiap set ciri x kepada sejumlah *class label* y yang ada (Prasetyo, 2014). Pada proses klasifikasi, metode yang dipakai yaitu metode *Support Vector Machine* (SVM). SVM adalah teknik klasifikasi yang telah umum dikembangkan serta diterapkan pada bidang pertanian. Metode SVM mampu bekerja pada sejumlah data dimensi tinggi dengan baik (Prasetyo, 2014). Dengan metode SVM dalam membentuk model klasifikasi hanya dibutuhkan sejumlah data terpilih saja (Prasetyo, 2014).

Pada beberapa implementasi terbukti bahwa *Support Vector Machine* memberikan hasil lebih bagus daripada *Artificial Neural Network* (ANN). ANN memberikan model klasifikasi yang *local optima*, sedangkan metode SVM memberikan model klasifikasi yang *global optima*. Solusi *local optima* akan memberikan hasil yang tidak selalu sama pada setiap saat *running* dijalankan. Sedangkan untuk *global optima* yaitu memberikan solusi yang sama untuk setiap *running* yang dijalankan. Teknik klasifikasi SVM ini sangat banyak digunakan karena memiliki performa yang baik dalam proses klasifikasi.

Metode klasifikasi SVM adalah metode yang hanya dapat melakukan klasifikasi biner (dua kelas). Sehingga untuk dapat digunakan dalam kasus klasifikasi dengan banyak kelas diperlukan pengembangan, yaitu metode *Multiclass Support Vector Machine* (M-SVM). Pendekatan *multiclass* SVM telah banyak dikembangkan dan digunakan dalam beberapa penelitian. Beberapa pendekatan *multiclass* SVM, yaitu *one against one* (OAO), *one against all* (OAA) serta *directed acyclic graph support vector machine* (DAGSVM).

Pendekatan *one-against-all* (OAA) merupakan pendekatan M-SVM paling sederhana, namun memiliki kelemahan, yaitu kemungkinan memiliki pasangan yang salah dalam sampel pelatihan antara label positif dan negatif dan juga waktu pelatihan dan evaluasi yang tinggi. Pendekatan *one-against-one* (OAO) memiliki kelebihan yaitu membutuhkan waktu lebih sedikit daripada OAA, karena pada pelatihan dengan metode OAO dilatih untuk dua kelas informasi dan melibatkan *support vector* yang jauh lebih sedikit. Kelemahan dari pendekatan OAO adalah *testing* yang kurang cepat, dikarenakan harus melakukan pengujian satu persatu pada setiap pasang kelas. Dalam mengatasi permasalahan pada pendekatan OAO dan OAA, maka digunakan pendekatan baru yaitu DAGSVM. Metode DAGSVM akan mengurangi waktu pelatihan dan evaluasi, dengan tetap mempertahankan akurasi dibandingkan dengan pendekatan OAO. Alasan ini yang menjadikan metode DAGSVM digunakan dalam penelitian penyakit daun tanaman kacang tanah.

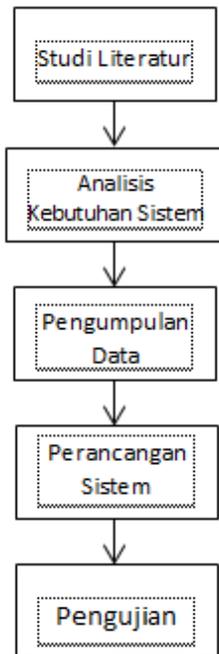
Dapat disimpulkan bahwa penulis memakai teknik GLCM sebagai ekstraksi tekstur serta HSV sebagai ekstraksi ciri warna. Klasifikasi dengan metode *Multiclass-SVM* untuk mengategorikan jenis penyakit yang menyerang daun tanaman kacang tanah.

3.2 Hipotesis

Dengan menggunakan metode GLCM dan HSV diharapkan mampu mengidentifikasi penyakit daun tanaman kacang tanah dan dengan menerapkan metode klasifikasi *Multiclass-SVM* dengan pendekatan DAGSVM untuk mengklasifikasikan jenis penyakit daun tanaman kacang tanah bercak daun, karat daun dan bercak mata diharapkan mampu memberikan tingkat akurasi yang tinggi.

BAB IV METODE PENELITIAN

Metode penelitian yang dilakukan untuk klasifikasi penyakit daun tanaman kacang tanah diperlihatkan oleh Gambar 4.1.



Gambar 4.1 Metode Penelitian

4.1 Studi Literatur

Studi literatur merupakan data yang terkait dengan dasar teori yang diperlukan dalam penelitian yang didapatkan dari literatur atau buku. Studi literatur yang berkaitan dalam penelitian klasifikasi penyakit daun kacang tanah adalah :

- Tanaman Kacang Tanah (Daun)
- Penyakit Tanaman Daun Kacang Tanah
- Pengolahan Citra Digital
- *Gray level co-occurrence matrix*
- Ruang warna HSV
- *Multiclass Support Vector Machine (M-SVM)*

4.2 Analisis Keperluan Sistem

Analisis keperluan sistem adalah kegiatan dengan tujuan untuk mendapatkan keperluan yang dibutuhkan dalam implementasi sistem. Analisis kebutuhan didapatkan

dengan menentukan data objek yang akan digunakan, kebutuhan yang dibutuhkan pada penelitian serta lokasi dari pengambilan objek yang akan digunakan.

Secara keseluruhan yang dibutuhkan untuk pembuatan sistem adalah :

1. Perangkat Lunak
 - OS Win 7, *Microsoft Office*, *MATLAB*
2. Perangkat Keras
 - Laptop *processor Intel Inside core i3*
3. Kebutuhan Bahan Data
 - Dataset daun kacang tanah yang terkena penyakit, daun kacang tanah dengan kondisi normal dan daun jenis lain.

4.3 Pengumpulan Dataset

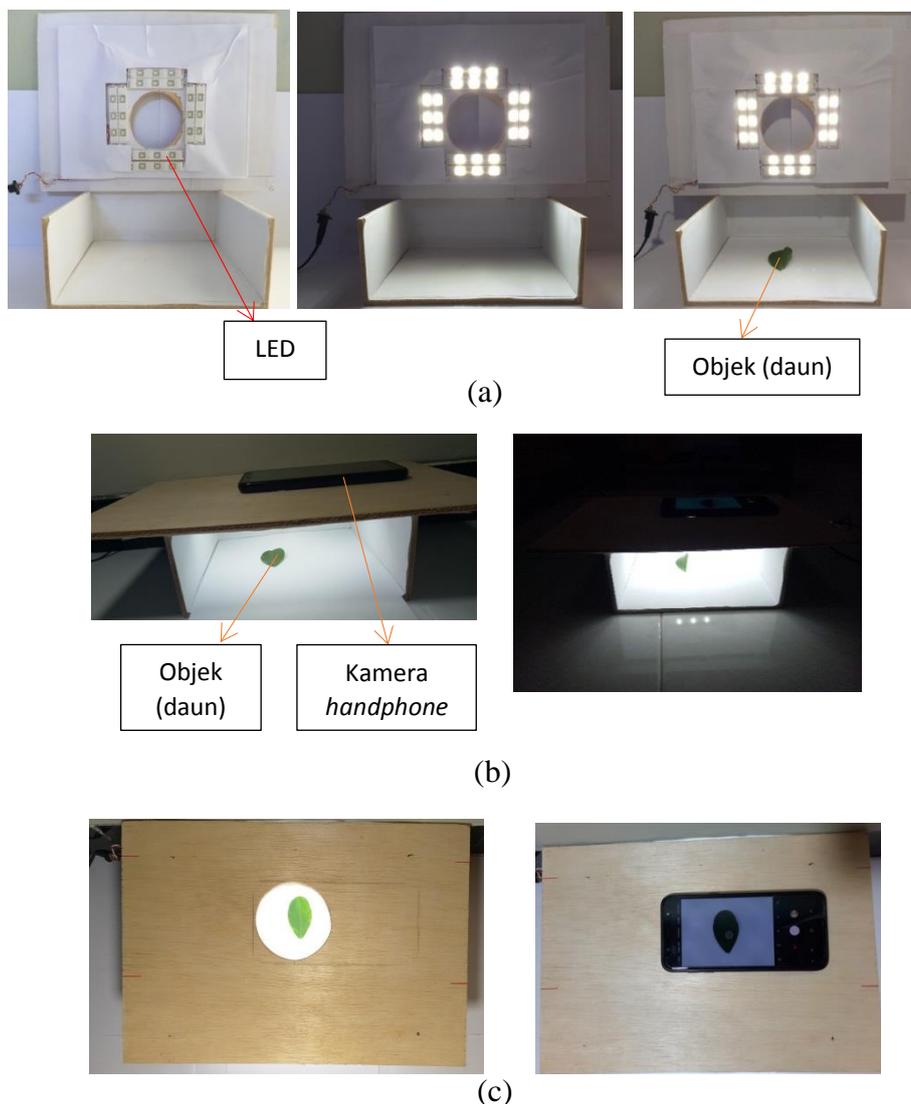
Dataset citra yang dipakai berupa data hasil proses akuisisi daun tanaman kacang tanah dengan langkah seperti berikut :

1) Pengambilan

Tahap pengambilan dan pengukuran sampel dilakukan pada daun tanaman kacang tanah yang telah berumur 1,5-2,5 bulan. Daun tanaman kacang tanah ini didapatkan dari beberapa lahan kebun di Tegalweru dan Landungsari. Selain itu daun tanaman kacang tanah juga didapatkan dari lahan kebun di Desa Tambakboyo, Kabupaten Sukoharjo. Data daun tanaman kacang tanah telah terlabeli secara manual oleh BPTP Jawa Timur bagian Hama dan Penyakit Tanaman.

2) Akuisisi Citra

Proses akuisisi citra pada daun tanaman kacang tanah menggunakan *lighting box* atau studio mini dan menggunakan kamera *handphone* yang diletakkan pada bagian atas *lighting box*. Daun diletakkan dalam *lighting box* dengan pencahayaan menggunakan lampu LED, kemudian dilakukan pengambilan gambar menggunakan kamera utama *handphone* pada objek daun tanaman kacang tanah. Tujuan dari penggunaan *lighting box* atau studio mini adalah untuk mendapatkan warna objek yang jelas melalui pencahayaan yang cukup dan untuk mengurangi pengaruh cahaya dari luar. Gambar 4.2 merupakan *lighting box* yang digunakan dalam proses akuisisi citra untuk mendapatkan citra daun pada masing-masing sampel daun tanaman kacang tanah.

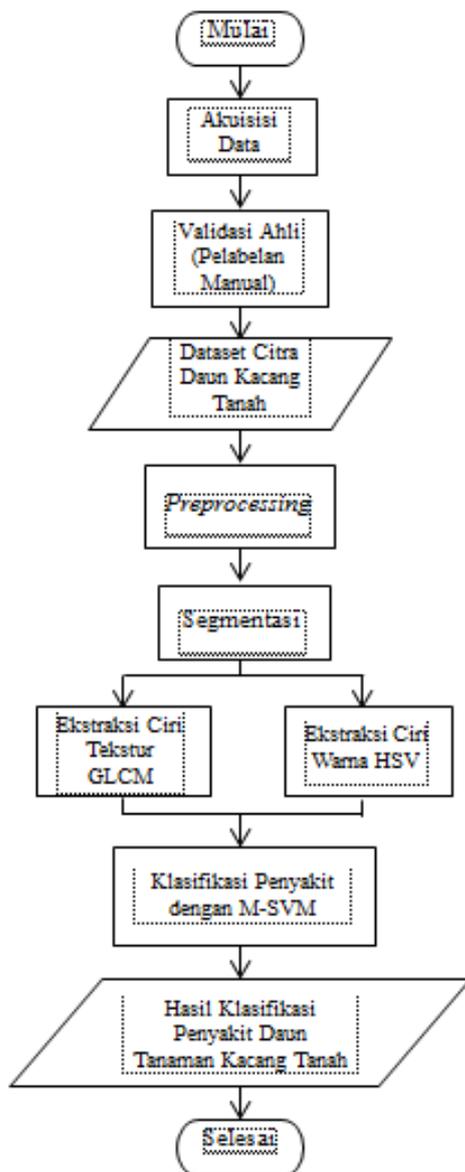


Gambar 4.2 Akuisisi citra (a) box keadaan terbuka (tampak depan), (b) box keadaan tertutup (tampak depan), (c) box keadaan tertutup (tampak atas)

4.4 Perancangan Sistem

Perancangan yang digunakan untuk identifikasi penyakit daun pada tanaman kacang tanah terdiri dari beberapa tahapan, yaitu proses input citra didapatkan dari proses akuisisi citra, hasil dari proses akuisisi citra berupa dataset daun tanaman kacang tanah akan digunakan ke dalam program dengan aras RGB. Setelah proses input citra selesai dilakukan, kemudian melakukan tahapan *pre-processing* yaitu *resize*. Citra hasil *pre-processing* digunakan sebagai input dalam proses segmentasi diawali dengan mengubah citra dari aras RGB ke $L^*a^*b^*$, selanjutnya digunakan bagian warna a^* serta b^* untuk proses segmentasi. Dalam proses segmentasi digunakan teknik K-means, kemudian dilanjutkan dengan proses operasi morfologi. Hasil citra dari proses segmentasi digunakan untuk proses pengambilan fitur tekstur serta warna. Proses untuk mengambil ciri tekstur

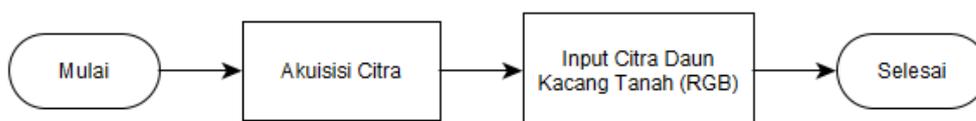
dengan GLCM dan untuk ciri warna dengan HSV. Tujuan dari proses ekstraksi ciri ini yaitu digunakan untuk memperoleh kondisi tekstur dan warna dari bagian daun berpenyakit, sehingga dapat dibedakan ciri dari masing-masing penyakit. Tahap selanjutnya adalah proses klasifikasi penyakit menggunakan metode *Multiclass SVM* yang mengklasifikasikan jenis penyakit daun tanaman kacang tanah berdasarkan ekstraksi ciri tekstur dan warna yang telah didapatkan dan digunakan sebagai input dalam proses klasifikasi. Kemudian hasil dari proses klasifikasi terdiri dari lima kelas, yaitu kelas bercak daun, karat daun, bercak mata dan kondisi daun normal dari daun tanaman kacang tanah, serta kondisi kelas daun lain. Hasil dari proses klasifikasi perlu dilakukan pengujian untuk mengetahui tingkat keakuratan dari hasil klasifikasi. Gambar 4.3 merupakan diagram alir perancangan sistem.



Gambar 4.3 Diagram alir perancangan sistem

4.4.1 Input Citra

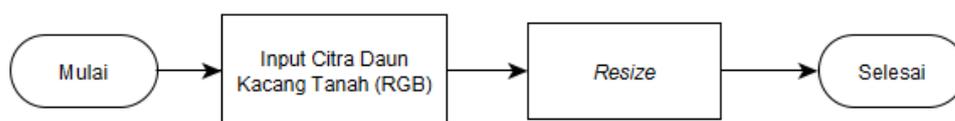
Input citra yang akan digunakan didapatkan dari hasil proses akuisisi gambar berupa citra daun tanaman kacang tanah yang akan digunakan sebagai input dalam program. Citra tanaman daun kacang tanah yang dihasilkan dari proses akuisisi citra memiliki ukuran kurang lebih 4608 x 3456 piksel dengan format *Joint Photographic Experts Group (JPEG)*. Data citra daun tanaman kacang tanah dalam penelitian ini terdiri dari dataset latih serta dataset uji. Citra yang digunakan terdiri dari citra daun tanaman kacang tanah yang terkena penyakit, yaitu kelas bercak daun, kelas karat daun, dan kelas bercak mata. Selain daun yang berpenyakit juga digunakan citra daun kacang tanah dari kelas normal dan daun kelas lain. Gambar 4.4 merupakan diagram alir dari proses input citra.



Gambar 4.4 Diagram alir *input* citra

4.4.2 Pre-processing

Proses *pre-processing* dilakukan untuk mengubah ukuran citra menjadi semakin besar atau semakin kecil, supaya didapatkan hasil yang baik saat identifikasi. Citra *input* yang dihasilkan dari proses akuisisi citra memiliki ukuran kurang lebih 4608 x 3456 piksel, citra *input* ini diatur kembali ukurannya menjadi 635 x 439 untuk meringankan proses kalkulasi. Gambar 4.5 merupakan diagram alir dari *pre-processing* citra.



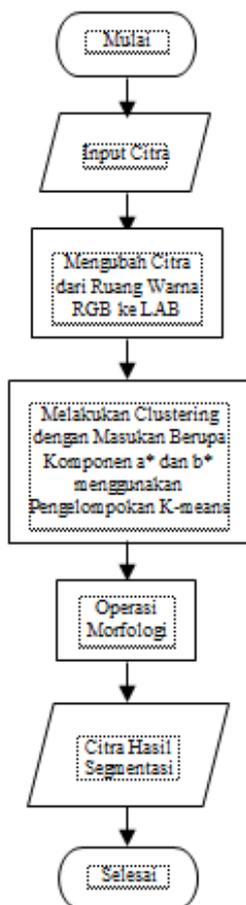
Gambar 4.5 Diagram alir *pre-processing*

4.4.3 Segmentasi Citra

Proses segmentasi citra dalam penelitian ini digunakan untuk mengambil daerah *Region Of Interest (ROI)* pada citra daun tanaman kacang tanah yang terdiri dari beberapa tahapan, yaitu terlebih dahulu dilakukan proses konversi dari aras RGB ke warna $L^*a^*b^*$. Persamaan yang digunakan untuk merubah dari RGB ke $L^*a^*b^*$ adalah Persamaan (2-1) sampai dengan (2-7).

Citra yang sudah berupa warna $L^*a^*b^*$, selanjutnya masuk kedalam proses *clustering* dengan masukan berupa variabel a^* serta b^* menggunakan pengelompokan K-means.

Clustering dengan K-means yaitu menetapkan jumlah klaster dan menentukan *centroid* dengan acak. Hasil dari proses K-means yaitu berupa citra hasil *cluster*. Citra hasil *cluster* berupa citra biner yang kemudian dilanjutkan dengan proses operasi morfologi, antara lain *filling* objek, yaitu proses untuk mengisi objek yang berlubang (*holes*). Setelah itu dilakukan proses subtraksi citra yaitu pengurangan citra hasil K-means *clustering* dengan citra hasil dari *filling object*. Citra dari hasil proses *subtraction* dilanjutkan dengan proses *bwareaopen*, yaitu menghilangkan objek dengan jumlah *pixel* yang kecil. Citra dari proses *bwareaopen* ini yang digunakan sebagai citra hasil segmentasi. Gambar 4.6 merupakan diagram dari tahapan segmentasi.



Gambar 4.6 Diagram alir segmentasi

4.4.4 Ekstraksi Ciri

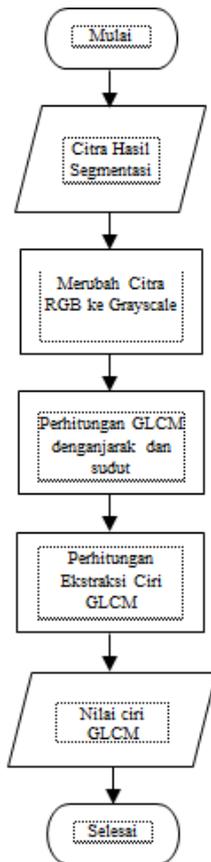
Ekstraksi ciri dalam penelitian ini berdasarkan tekstur dan warna. Pengambilan fitur tekstur dengan GLCM dan fitur warna menggunakan ruang warna HSV. Berikut adalah penjelasan dari masing-masing pengambilan ciri dari tekstur dan ciri dari warna.

4.4.4.1 Ekstraksi Ciri pada Tekstur

Dalam penelitian digunakan ekstraksi ciri tekstur memakai metode GLCM. Sebelum proses ekstraksi tekstur dimulai citra RGB hasil segmentasi perlu dirubah ke dalam aras *grayscale*. Hal ini bertujuan supaya dapat digunakan sebagai masukan dalam proses GLCM. GLCM merupakan perhitungan pada tekstur dengan statistik orde kedua, dimana sepasang piksel dari citra diperhitungkan (Kadir, dkk, 2013). Metode GLCM yaitu menunjukkan seberapa banyak munculnya sepasang piksel berdasarkan *distance* dan sudut tertentu pada gambar.

Proses untuk analisis tekstur menggunakan GLCM, dimulai dari membuat matriks kookurensi. Kemudian mengisi matriks kookurensi, berdasarkan seberapa banyak munculnya hubungan pasangan keabuan piksel dari citra dengan *distance* dan sudut tertentu. Pada penelitian ini menggunakan empat orientasi arah yaitu 0° ; 45° ; 90° ; 135° dan *distance* $d=1$. Pemilihan orientasi serta jarak ini berdasarkan pada penelitian Listia serta Harjoko tahun 2014, yaitu melakukan penelitian terhadap citra *mammogram*. Hasil dari penelitian ini, yaitu ciri ekstraksi dengan GLCM pada 4 sudut yaitu 0° ; 45° ; 90° ; 135° dan *distance* ($d=1$) memiliki hasil terbaik. Berdasarkan penelitian ini maka digunakan $d=1$ dengan orientasi empat sudut, yaitu 0° ; 45° ; 90° ; 135° diharapkan juga memberikan hasil terbaik untuk mengenali tekstur daun berpenyakit.

Langkah selanjutnya, yaitu menghitung ciri GLCM, ciri GLCM yang diekstraksi, yaitu *angular second moment*, *contrast*, *inverse difference moment*, *entropy*, *correlation*, *variance*, *difference entropy*, *sum average*, *sum entropy*, *diffrence variance*, *sum variance* dengan menggunakan persamaan (2-14) sampai (2-24). Gambar 4.7 adalah diagram alir metode GLCM.



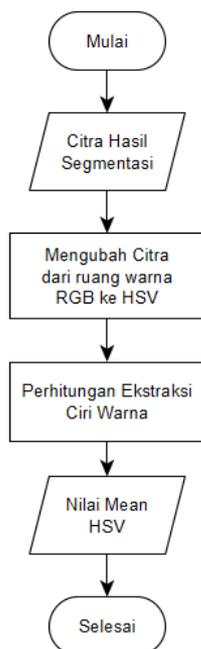
Gambar 4.7 Diagram alir GLCM

4.4.4.2 Ekstraksi Ciri pada Warna

Ciri ekstraksi warna diperoleh menggunakan ruang HSV. Sebelum proses ekstraksi warna, citra dalam aras RGB diubah menjadi ruang warna HSV. Persamaan untuk mengkonversi dari ruang warna RGB ke HSV yang digunakan adalah persamaan (2-8) sampai (2-12). Setelah ruang warna HSV didapatkan, selanjutnya adalah menghitung ciri *mean* dalam ruang warna HSV. Perhitungan *mean* untuk mempresentasikan nilai *mean* dari setiap warna. Nilai *mean* H, S dan V dihitung dengan menggunakan persamaan (4-1).

$$\begin{aligned} \mu_H &= \frac{H}{H + S + V} \\ \mu_S &= \frac{S}{H + S + V} \\ \mu_V &= \frac{V}{H + S + V} \end{aligned} \quad (4-1)$$

Sehingga akan didapatkan ciri warna dari masing-masing kondisi daun yang terkena penyakit. Gambar 4.8 merupakan diagram alir pengambilan ciri warna dalam ruang warna HSV.

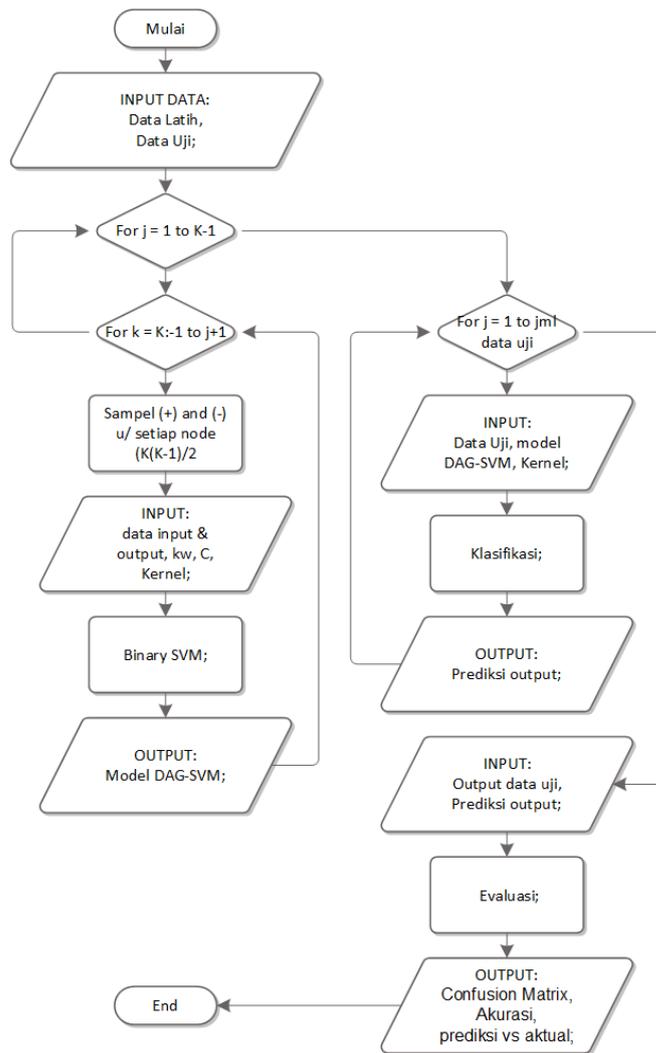


Gambar 4.8 Bagan ekstraksi ciri warna HSV

4.4.5 Klasifikasi *Multiclass-SVM*

Metode klasifikasi *M-SVM* adalah metode yang diaplikasikan yang merupakan pengembangan dari *SVM* yang hanya mampu mengklasifikasikan permasalahan dua kelas. Metode *M-SVM* digunakan pada penelitian ini karena ada lima kelas kondisi daun yang akan diklasifikasikan. Lima kelas yang akan diklasifikasikan yaitu kondisi penyakit bercak daun sebagai kelas 1, kondisi penyakit karat daun sebagai kelas 2, kondisi penyakit bercak mata sebagai kelas 3, kondisi daun normal sebagai kelas 4 dan kondisi daun lain sebagai kelas 5. Proses klasifikasi ini yaitu mendapatkan *input* dari nilai ciri tekstur dengan *GLCM* dan ciri warna dalam ruang warna HSV.

Proses klasifikasi yang digunakan adalah metode *M-SVM* dengan menggunakan teknik *Directed Acyclic Graph Support Vector Machine (DAGSVM)* yang akan menghasilkan keluaran berupa hasil klasifikasi. Gambar 4.9 merupakan diagram alir dari proses *Support Vector Machine (SVM)*.



Gambar 4.9 Klasifikasi DAGSVM

Proses yang dilakukan dalam tahapan klasifikasi penyakit daun kacang tanah dengan metode M-SVM strategi DAGSVM terdiri dari :

1. *Input data*

Input data ini terdiri dari data latih yang digunakan dalam pelatihan/pemodelan DAGSVM. Data uji digunakan untuk menguji kinerja hasil pelatihan DAGSVM yang telah diperoleh pada tahap pelatihan.

For $j = 1$ to $K-1$ yang mana K merupakan jumlah label class, yaitu ada 5.

For $k = K:-1$ to $j+1$

2. Menentukan sample untuk pelatihan pada setiap node (10 node, $K(K-1)/2$). Sesuai dengan perulangan j dan k , sehingga terbentuk 10 sample pelatihan yang mana setiap node memiliki class berpasangan (+) dan (-) dengan mengikuti aturan DAG.

3. Proses Pelatihan SVM

- *Input X*, merupakan *input* dari data latih pada node yang dimaksud.

- *Input Y*, merupakan output/class dari data latih pada *node* yang dimaksud.
- *Input kw*, digunakan untuk desired-kernel, dengan nilai awal = -1.
- *Input C*, merupakan *box constraint* yang akan diterapkan pada setiap model pengklasifikasi DAG-SVM.
- *Input Kernel*, merupakan opsi untuk memilih metode kernel yang akan digunakan, antara lain: 1) Linear; 2) Polynomial Degree 2 s/d 6; dan 3) RBF.
- Proses Binary_SVM, proses pelatihan *binary SVM* untuk setiap *node*.
- *Output Model_DAG-SVM*, merupakan *output* atau model hasil pelatihan DAG-SVM untuk setiap *node*.

4. Proses Pengujian

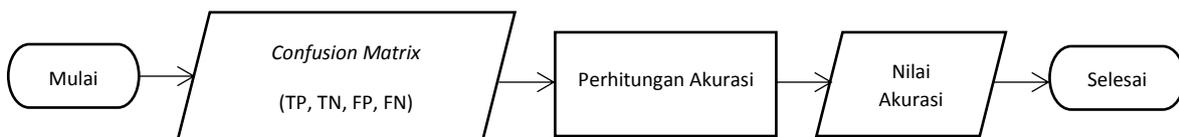
- *Input xt*, merupakan *input* data uji yang akan diprediksi outputnya oleh model DAG-SVM.
- *Input model_DAG-SVM*, merupakan model DAG-SVM yang telah dihasilkan pada tahap pelatihan untuk setiap *node*.
- *Input Kernel*, merupakan opsi untuk memilih metode kernel yang akan digunakan, antara lain: 1) Linear; 2) Polynomial Degree; dan 3) RBF.
- Proses klasifikasi, proses untuk memprediksi *output* dari setiap data uji menggunakan model DAG-SVM.
- *Output Predicted_Output*, merupakan hasil prediksi *output* dari data uji dari proses klasifikasi sebelumnya.

5. Proses Evaluasi

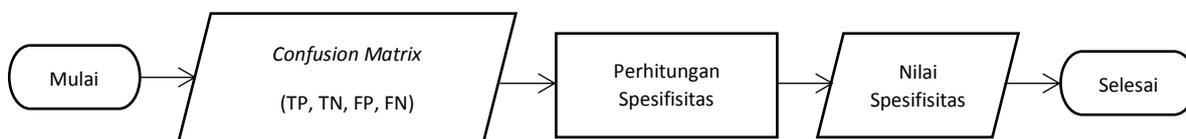
- *Input yt*, merupakan aktual *output* dari data uji yang akan digunakan untuk mengukur kinerja klasifikasi model DAG-SVM.
- *Input Predicted_Output*, merupakan hasil prediksi *output* dari data uji dari proses klasifikasi sebelumnya.
- Proses Evaluasi, yaitu untuk mengukur kinerja dari model DAG-SVM dengan menggunakan *Confusion Matrix* sehingga diperoleh kinerja akurasi, sensitifitas, spesifitas.
- *Output ConMat*, merupakan hasil *confusion matrix* dari proses evaluasi.
- *Output acc*, merupakan hasil akurasi model DAG-SVM dari proses evaluasi.
- *Output predictedVSactual*, merupakan daftar output yang diprediksi model DAG-SVM dan yang merupakan aktual *output*.

4.5 Pengujian

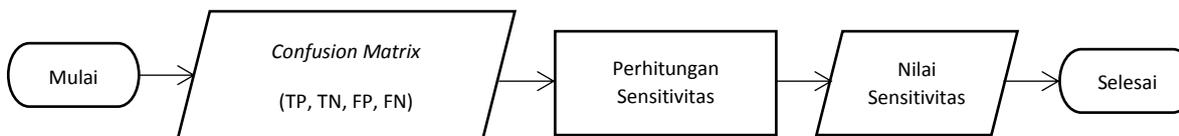
Pengujian dalam penelitian ini diperlukan untuk mengetahui bahwa sistem yang sudah dibangun bisa bekerja sesuai kebutuhan yang diinginkan. Hasil dari proses pengujian adalah untuk mengetahui analisis dari performansi sistem dalam mengklasifikasikan penyakit daun tanaman kacang tanah. Variabel yang dianalisis adalah *confusion matrix*. Parameter untuk mengukur performansi sistem yang diperoleh dari *confusion matrix* adalah akurasi, sensitivitas dan spesifisitas. Akurasi, spesifisitas dan sensitivitas dihitung dengan Persamaan (2-51) sampai (2-53). Gambar 4.10 sampai Gambar 4.12 merupakan tahapan perhitungan dari nilai akurasi, nilai spesifisitas dan nilai sensitivitas pada sistem yang didesain pada penelitian ini.



Gambar 4.10 Bagan dari perhitungan akurasi



Gambar 4.11 Bagan dari perhitungan spesifisitas



Gambar 4.12 Bagan dari perhitungan sensitivitas

Selain itu perlu dilakukan pengujian sistem untuk memperoleh validasi dari sistem yang telah dibuat. Pengujian pada sistem ini adalah pengujian terhadap penggunaan *kernel* dalam proses klasifikasi. Pengujian terhadap *kernel* dilakukan karena penggunaan jenis *kernel* berpengaruh terhadap proses pencarian *hyperplane* secara optimal dalam klasifikasi SVM *non-linear*. Pada penelitian ini digunakan tiga fungsi kernel, yaitu linear, *polynomial* dan RBF.

BAB V

HASIL DAN PEMBAHASAN

Pada Bab V menerangkan prosedur pengolahan citra penyakit daun tanaman kacang tanah, hasil penelitian serta pembahasan klasifikasi penyakit daun tanaman kacang tanah berdasarkan metode ciri ekstraksi tekstur GLCM dan ekstraksi ciri ekstraksi warna HSV dengan menggunakan metode SVM untuk klasifikasinya.

5.1 Perancangan Sistem

Dalam mengklasifikasikan penyakit daun kacang tanah dibutuhkan beberapa proses, yaitu proses *preprocessing*, segmentasi, pengambilan/ekstraksi ciri serta klasifikasi.

5.1.1 Preprocessing

Preprocessing dilakukan dengan pengurangan ukuran citra (*resizing*). Citra daun kacang tanah dengan ukuran 4608x3456 *pixel* dikurangi ukuran citranya 0.1x menjadi 635x439 *pixel*. Tujuan dari *resizing* ini adalah untuk mempercepat proses pengolahan citra daun kacang tanah. Proses *resize* dalam matlab digunakan fungsi *imresize* yang sudah terdapat di dalam *toolbox* MATLAB. Proses *imresize* menggunakan *syntax* dengan MATLAB sebagai berikut:

```
% memperkecil ukuran citra menjadi 0.1x ukuran semula untuk mempercepat
% komputasi
Img = imresize(Img,0.1);
figure, imshow(Img);
```

5.1.2 Segmentasi

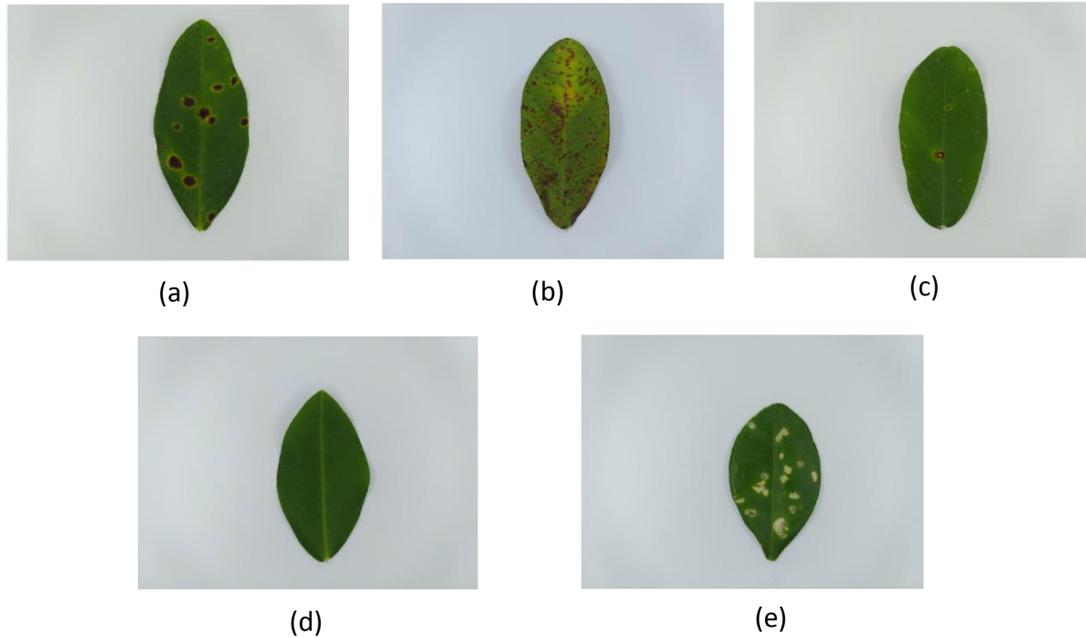
Proses segmentasi adalah proses untuk mengambil *Region Of Interest* (ROI) dari citra. ROI yang diambil adalah bagian yang berpenyakit pada gambar daun kacang tanah. Proses segmentasi terdiri dari beberapa proses, yaitu metode K-means, *filling* objek, *subtraction*, dan proses penghilangan objek dengan jumlah *pixel* yang kecil (*bwareaopen*).

Proses segmentasi diawali dengan mengubah citra daun tanaman kacang tanah dalam ruang warna RGB menjadi citra dalam ruang warna LAB. Proses konversi citra RGB ke LAB terdiri dari beberapa tahapan, yaitu

1. *Input* citra daun tanaman kacang tanah RGB. Gambar 5.1 merupakan sampel citra daun tanaman kacang tanah yang telah melalui proses *imresize*. Gambar 5.1 merupakan sampel data RGB dari citra daun kacang tanah.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.7804	0.7804	0.7843	0.7843	0.7882	0.7843	0.7804	0.7843	0.7843	0.7843	0.7843	0.7843	0.788
2	0.8039	0.8039	0.8078	0.8078	0.8118	0.8078	0.8039	0.8078	0.8078	0.8078	0.8039	0.8078	0.811
3	0.7961	0.7961	0.7961	0.8000	0.7961	0.7961	0.7961	0.8000	0.8000	0.8000	0.8000	0.8000	0.803
4													

Gambar 5.1 Sampel data RGB citra daun kacang tanah



Gambar 5.2 Sampel data citra daun kacang tanah dalam RGB (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal, (e) daun lain

- Memasukkan nilai *threshold*, yaitu 0.008856. *Input threshold* menggunakan *syntax* sebagai berikut:

```

% Set a threshold
T = 0.008856;
[M, N] = size(r);
    
```

- Menghitung XYZ dengan menggunakan Persamaan (2-4) sampai (2-6). Gambar 5.3 merupakan sampel data hasil perhitungan XYZ.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.7530	0.7530	0.7560	0.7567	0.7590	0.7560	0.7530	0.7567	0.7567	0.7567	0.7553	0.7567	0.760
2	0.7984	0.7984	0.8020	0.8023	0.8056	0.8020	0.7984	0.8023	0.8023	0.8023	0.7995	0.8023	0.806
3	0.8674	0.8674	0.8679	0.8716	0.8685	0.8679	0.8674	0.8716	0.8716	0.8716	0.8712	0.8716	0.875
4													

Gambar 5.3 Sampel data XYZ

- Menghitung $f(X)$, $f(Y)$ dan $f(Z)$ dengan menggunakan Persamaan (2-10). Gambar 5.4 merupakan sampel data hasil perhitungan $f(X)$, $f(Y)$ dan $f(Z)$.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.9253	0.9253	0.9265	0.9268	0.9278	0.9265	0.9253	0.9268	0.9268	0.9268	0.9263	0.9268	0.928
2													

(a)

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.9277	0.9277	0.9291	0.9292	0.9305	0.9291	0.9277	0.9292	0.9292	0.9292	0.9281	0.9292	0.930
2													

(b)

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0.9270	0.9270	0.9272	0.9285	0.9274	0.9272	0.9270	0.9285	0.9285	0.9285	0.9284	0.9285	0.930
2													

(c)

Gambar 5.4 (a) sampel data f(X), (b) sampel data f(Y), dan (c) sampel data f(Z)

5. Menghitung nilai L, A dan B dengan menggunakan Persamaan (2-7) sampai (2-9).

Gambar 5.5 menunjukkan sampel data hasil perhitungan LAB. Gambar 5.6 merupakan sampel citra daun kacang tanah dalam ruang warna LAB

```

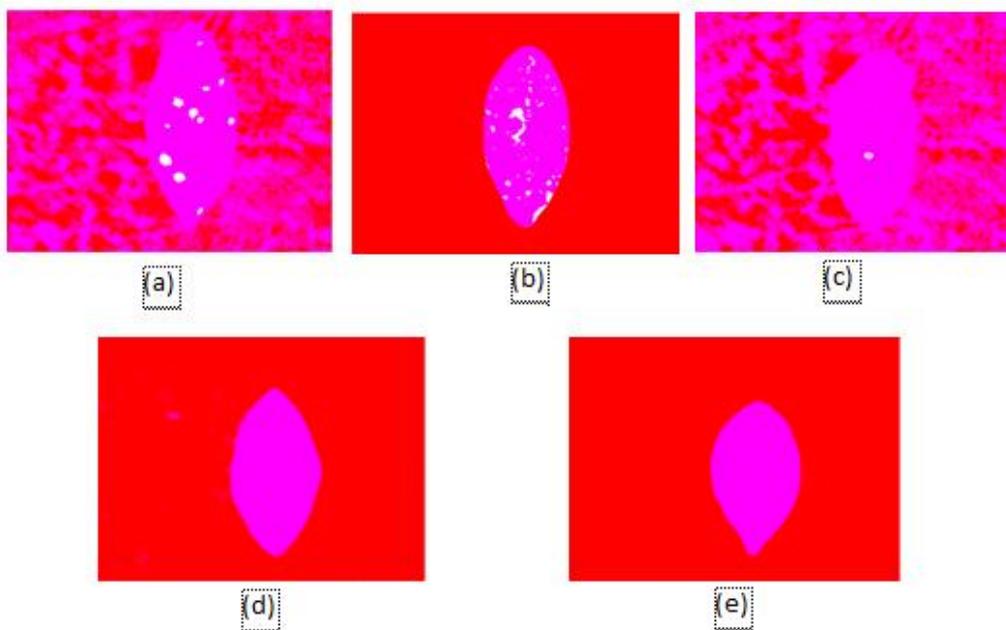
val(:,:,1) =
Columns 1 through 12
91.6108 91.4847 91.8368 91.7111 91.7994 91.8121 91.9375 91.7994 91.7494 91.5861 91.8241 91.6984
91.6108 91.6984 91.8741 91.6984 91.8241 91.9621 91.9495 91.7868 91.9495 91.7741 91.6108 91.6984
91.7741 91.6857 91.6984 91.8614 91.8241 91.8241 91.8741 91.6984 91.9621 91.7868 91.7494 91.8241
91.7868 91.9368 91.8114 91.9741 92.0239 91.9867 91.9113 91.7358 91.6483 91.7868 91.7868 91.9621
91.9368 91.7741 91.8114 91.9741 91.8741 91.8741 91.9113 91.8741 91.6610 91.7868 91.9249 91.8368
91.7741 91.7614 91.8996 91.8114 91.6984 91.8741 92.0491 91.8741 91.8741 91.7868 91.7868 91.7868
91.6108 91.5981 91.8996 91.9368 91.8241 91.6984 91.8741 91.8741 91.8741 91.8741 91.8368 91.8241 91.8368
91.7868 91.5981 91.7614 91.9368 91.8241 91.8241 91.6984 91.6984 91.8241 91.8741 91.6984 91.6984
91.7868 91.7868 91.8114 91.8114 91.8241 91.7111 91.6984 91.8741 91.9621 91.8614 91.8241 91.8741
91.7868 91.6108 91.7868 91.6984 91.8241 91.6483 91.6984 91.6984 91.8241 91.8614 91.8741 91.6984
91.6610 91.6984 91.8241 91.6984 91.8114 91.7614 91.6483 91.7868 91.7868 91.8368 91.8741 91.8741
91.7868 91.8741 91.7868 91.8614 91.9867 91.9368 91.7868 91.9621 91.9621 91.9621 91.9993 91.8368
91.9621 91.9621 91.9621 91.9368 91.9368 91.9368 91.9621 91.9621 91.9621 92.1369 92.1369 91.9621
91.7868 91.9621 91.9621 91.9621 91.9621 91.9621 92.0619 91.9495 92.1369 92.1369 91.9621 91.9621
91.9621 91.7868 91.9621 91.7741 91.9368 92.0991 91.9495 91.9621 91.9495 91.9621 91.9495 92.1369
91.9621 91.9621 91.7994 91.9495 91.7614 91.9368 91.9495 91.7868 92.1243 92.1117 92.1117 91.9621
91.8368 91.7994 91.9621 91.9621 91.9621 91.9621 91.7741 91.9495 91.9621 92.1243 92.1117 91.7868
91.9621 91.8121 91.9747 91.7868 91.9621 91.7994 91.9621 92.1369 91.9993 92.1488 92.1117 92.1117
    
```

```

val(:,:,2) =
Columns 1 through 12
-1.1901 -0.9337 -0.9276 -0.6720 -1.0965 -1.0068 -1.2615 -1.0965 -1.3556 -1.2698 -1.0172 -0.7616
-1.1901 -0.7616 -0.7591 -0.7616 -1.0172 -1.1824 -1.2719 -1.1862 -1.2719 -1.2761 -1.1901 -0.7616
-1.2761 -0.8513 -0.7616 -0.8485 -1.0172 -1.0172 -0.7591 -0.7616 -1.1824 -1.1862 -1.3556 -1.0172
-1.1862 -1.3615 -1.1069 -1.1927 -0.9350 -1.1033 -0.5910 -0.5929 -1.0205 -1.1862 -1.1862 -1.1824
-1.3615 -1.2761 -1.1069 -1.1927 -0.7591 -0.7591 -0.5910 -0.7591 -0.9306 -1.1862 -1.3512 -0.9276
-1.2761 -1.3660 -1.5307 -1.1069 -0.7616 -0.7591 -0.7567 -0.7591 -0.7591 -1.1862 -1.1862 -1.1862
-1.1901 -1.2803 -1.5307 -1.3615 -1.0172 -0.7616 -0.7591 -0.7591 -0.7591 -0.9276 -1.0172 -0.9276
-1.1862 -1.2803 -1.3660 -1.3615 -1.0172 -1.0172 -0.7616 -0.7616 -1.0172 -0.7591 -0.7616 -0.7616
-1.1862 -1.1862 -1.1069 -1.1069 -1.0172 -0.6720 -0.7616 -0.7591 -1.1824 -0.8485 -1.0172 -0.7591
-1.1862 -1.1901 -1.1862 -0.7616 -1.0172 -1.0205 -0.7616 -0.7616 -1.0172 -0.8485 -0.7591 -0.7616
-0.9306 -0.7616 -1.0172 -0.7616 -1.1069 -1.3660 -1.0205 -1.1862 -1.1862 -0.9276 -0.7591 -0.7591
-1.1862 -0.7591 -1.1862 -0.8485 -1.1033 -1.3615 -1.1862 -1.1824 -1.1824 -1.1824 -1.0139 -0.9276
-1.1824 -1.1824 -1.1824 -1.3615 -1.3615 -1.3615 -1.1824 -1.1824 -1.1824 -1.1785 -1.1785 -1.1824
-1.1862 -1.1824 -1.1824 -1.1824 -1.3615 -1.6153 -1.2719 -1.1785 -1.1785 -1.1824 -1.1824 -1.1824
-1.1824 -1.1862 -1.1824 -1.2761 -1.3615 -1.4465 -1.2719 -1.1824 -1.2719 -1.1824 -1.2719 -1.1785
-1.1824 -1.1824 -1.0965 -1.2719 -1.3660 -1.3615 -1.2719 -1.1862 -1.2678 -1.3571 -1.3571 -1.1824
-0.9276 -1.0965 -1.1824 -1.1824 -1.2719 -1.2719 -1.2719 -1.1824 -1.2678 -1.3571 -1.2678 -1.1862
-1.1824 -1.0068 -1.0929 -1.1862 -1.1824 -1.0965 -1.1824 -1.1785 -1.0139 -1.1889 -1.3571 -1.3571
-1.0068 -1.0035 -0.8381 -0.9246 -0.9246 -0.9276 -1.4409 -1.1824 -0.7567 -1.1889 -1.1927 -1.3615
    
```

Columns 1 through 12											
0.1312	-0.0530	-0.0526	-0.2361	-0.1116	-0.3533	-0.1701	-0.1116	0.0718	-0.1712	0.1898	0.0064
0.1312	0.0064	0.0063	0.0064	0.1898	0.1304	0.3728	0.1308	0.3728	0.3740	0.1312	0.0064
0.3740	0.2496	0.0064	0.2487	0.1898	0.1898	0.0063	0.0064	0.1304	0.1308	0.0718	0.1898
0.1308	0.6159	0.4330	0.6747	0.4903	0.4316	0.0652	0.0654	0.1904	0.1308	0.1308	0.1304
0.6159	0.3740	0.4330	0.6747	0.0063	0.0063	0.0652	0.0063	-0.0528	0.1308	0.0715	-0.0526
0.3740	0.6179	0.5570	0.4330	0.0064	0.0063	0.0063	0.0063	0.0063	0.1308	0.1308	0.1308
0.1312	0.3752	0.5570	0.6159	0.1898	0.0064	0.0063	0.0063	0.0063	-0.0526	0.1898	-0.0526
0.1308	0.3752	0.6179	0.6159	0.1898	0.1898	0.0064	0.0064	0.1898	0.0063	0.0064	0.0064
0.1308	0.1308	0.4330	0.4330	0.1898	-0.2361	0.0064	0.0063	0.1304	0.2487	0.1898	0.0063
0.1308	0.1312	0.1308	0.0064	0.1898	0.1904	0.0064	0.0064	0.1898	0.2487	0.0063	0.0064
-0.0528	0.0064	0.1898	0.0064	0.4330	0.6179	0.1904	0.1308	0.1308	-0.0526	0.0063	0.0063
0.1308	0.0063	0.1308	0.2487	0.4316	0.6159	0.1308	0.1304	0.1304	0.1304	0.1892	-0.0526
0.1304	0.1304	0.1304	0.6159	0.6159	0.6159	0.1304	0.1304	0.1304	0.1300	0.1300	0.1304
0.1308	0.1304	0.1304	0.1304	0.6159	0.7983	0.3728	0.1300	0.1300	0.1304	0.1304	0.1304
0.1304	0.1308	0.1304	0.3740	0.6159	0.8570	0.3728	0.1304	0.3728	0.1304	0.3728	0.1300
0.1304	0.1304	-0.1116	0.3728	0.6179	0.6159	0.3728	0.1308	0.3716	0.6139	0.6139	0.1304
-0.0526	-0.1116	0.1304	0.1304	0.3728	0.3740	0.3728	0.1304	0.3716	0.6139	0.3716	0.1308
0.1304	-0.3533	-0.1112	0.1308	0.1304	-0.1116	0.1304	0.1300	0.1892	0.6725	0.6139	0.6139
-0.3533	-0.3521	-0.2943	-0.0524	-0.0524	-0.0526	0.3139	0.1304	0.0063	0.6725	0.6747	0.6159

Gambar 5.5 Sampel data LAB citra daun kacang tanah



Gambar 5.6 Sampel daun kacang tanah dalam ruang warna LAB (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal, (e) daun lain

Setelah citra daun tanaman kacang tanah dalam ruang warna LAB telah didapatkan, proses selanjutnya adalah metode *clustering* K-means. Pada proses ini, hanya komponen *a dan *b dalam ruang warna LAB yang diproses menggunakan metode K-means. Terdapat beberapa tahapan yang digunakan dalam proses *clustering* K-means, yaitu

1. *Input* komponen *a dan *b. Gambar 5.7 adalah sampel data nilai komponen *a dan *b.

	1	2
1	-1.1901	0.1312
2	-1.1901	0.1312
3	-1.2761	0.3740
4	-1.1862	0.1308
5	-1.3615	0.6159
6	-1.2761	0.3740
7	-1.1901	0.1312
8	-1.1862	0.1308
9	-1.1862	0.1308
10	-1.1862	0.1308
11	-0.9306	-0.0528
12	-1.1862	0.1308
13	-1.1824	0.1304
14	-1.1862	0.1308
15	-1.1824	0.1304
16	-1.1824	0.1304
17	-0.9276	-0.0526
18	-1.1824	0.1304
19	-1.0068	-0.3533

Gambar 5.7 Sampel data komponen *a dan *b

2. Menentukan jumlah *cluster* yang ingin dibentuk. Dengan menggunakan *syntax* sebagai berikut:

```
F = ab;
K = 2;
```

3. Membangkitkan *centroid* sesuai jumlah *cluster* secara *random*. Gambar 5.8 merupakan sampel nilai *centroid* secara *random*.

```
CENTS =
-0.8811  -2.7497
-0.5562  -2.1107
```

Gambar 5.8 Sampel data *centroid* secara acak

4. Melakukan perhitungan jarak dari tiap data terhadap setiap *centroid*. Perhitungan jarak pada penelitian ini menggunakan *Manhattan Distance*. *Manhattan distance* dihitung dengan menggunakan Persamaan (2-13). Gambar 5.9 adalah sampel data nilai hasil dari perhitungan jarak dengan *manhattan distance*.

	1	2
1	0.2597	31.2635
2	0.2597	31.2635
3	0.0276	31.0163
4	0.2610	31.2661
5	0.2573	30.7702
6	0.0276	31.0163
7	0.2597	31.2635
8	0.2610	31.2661
9	0.2610	31.2661
10	0.2610	31.2661
11	0.5411	31.5645
12	0.2610	31.2661
13	0.2624	31.2687
14	0.2610	31.2661
15	0.2624	31.2687
16	0.2624	31.2687
17	0.5428	31.5661
18	0.2624	31.2687
19	0.7763	31.7642

Gambar 5.9 Sampel data hasil perhitungan *manhattan distance*

- Memilih *centroid* terdekat. Gambar 5.10 merupakan sampel hasil pengelompokan berdasarkan *centroid* terdekat.

	1	2	3	4
1	0.2597	31.2635	1	0.2597
2	0.2597	31.2635	1	0.2597
3	0.0276	31.0163	1	0.0276
4	0.2610	31.2661	1	0.2610
5	0.2573	30.7702	1	0.2573
6	0.0276	31.0163	1	0.0276
7	0.2597	31.2635	1	0.2597
8	0.2610	31.2661	1	0.2610
9	0.2610	31.2661	1	0.2610
10	0.2610	31.2661	1	0.2610
11	0.5411	31.5645	1	0.5411
12	0.2610	31.2661	1	0.2610
13	0.2624	31.2687	1	0.2624
14	0.2610	31.2661	1	0.2610
15	0.2624	31.2687	1	0.2624
16	0.2624	31.2687	1	0.2624
17	0.5428	31.5661	1	0.5428
18	0.2624	31.2687	1	0.2624
19	0.7763	31.7642	1	0.7763

Gambar 5.10 Sampel hasil pengelompokan *centroid* terdekat

- Melakukan perhitungan untuk mendapatkan *centroid* baru dengan menghitung *mean* dari setiap *cluster*. Gambar 5.11 merupakan sampel data nilai *centroid* baru.

```

CENTS =
-0.6640  -2.7540
-0.5562  -2.1107

CENTS =
-0.6640  -2.7540
-3.1340   0.8171

CENTS =
-0.8663  -2.2049
-3.1340   0.8171

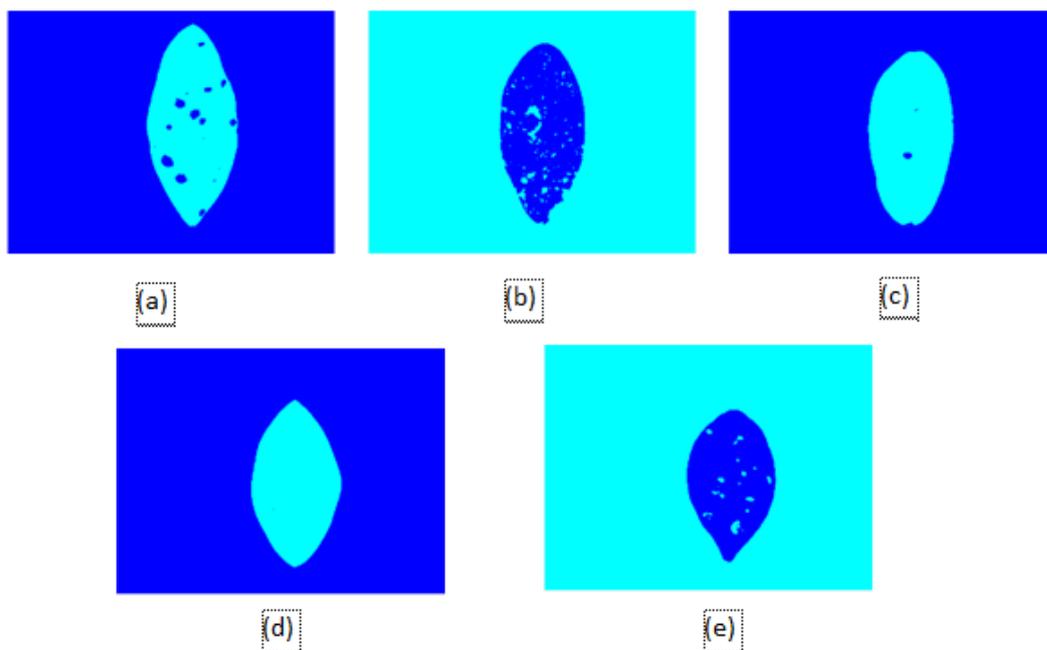
```

Gambar 5.11 Sampel data nilai *centroid* baru

- Proses ini dilakukan sampai mencapai maksimum iterasi.

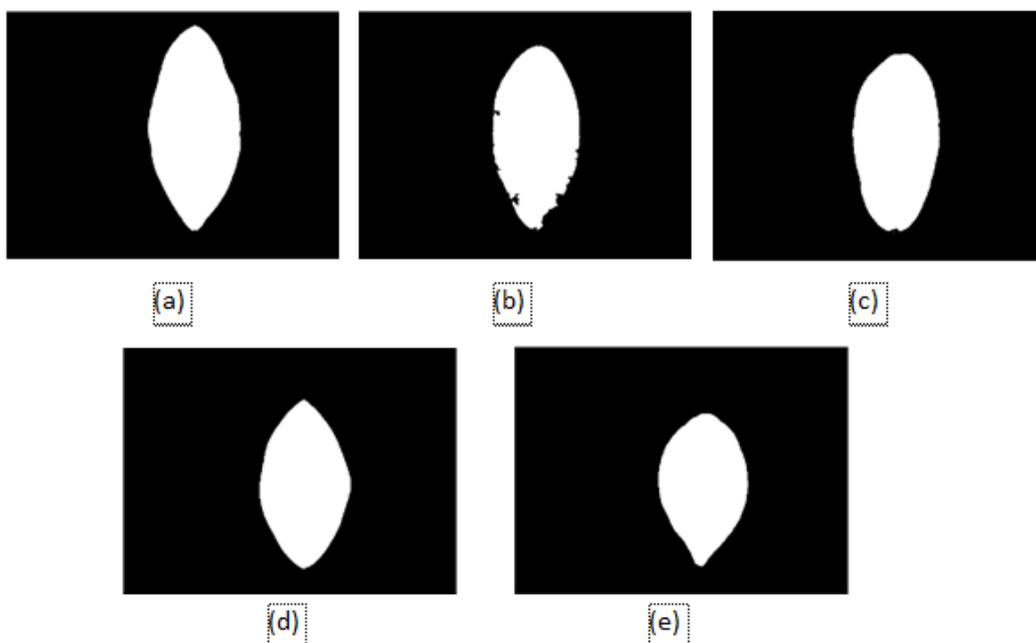
Hasil dari proses *clustering* K-means berupa data tiap *cluster*. Dalam penelitian digunakan *cluster* (K=2), yaitu *cluster* 1 dipresentasikan sebagai *background* dan *cluster* 2 dipresentasikan sebagai bagian daun. *Cluster* yang dipilih adalah region *cluster* yang

luasnya minimal, yaitu yang mempresentasikan bagian daun. Gambar 5.12 menunjukkan hasil dari proses *clustering* K-means.



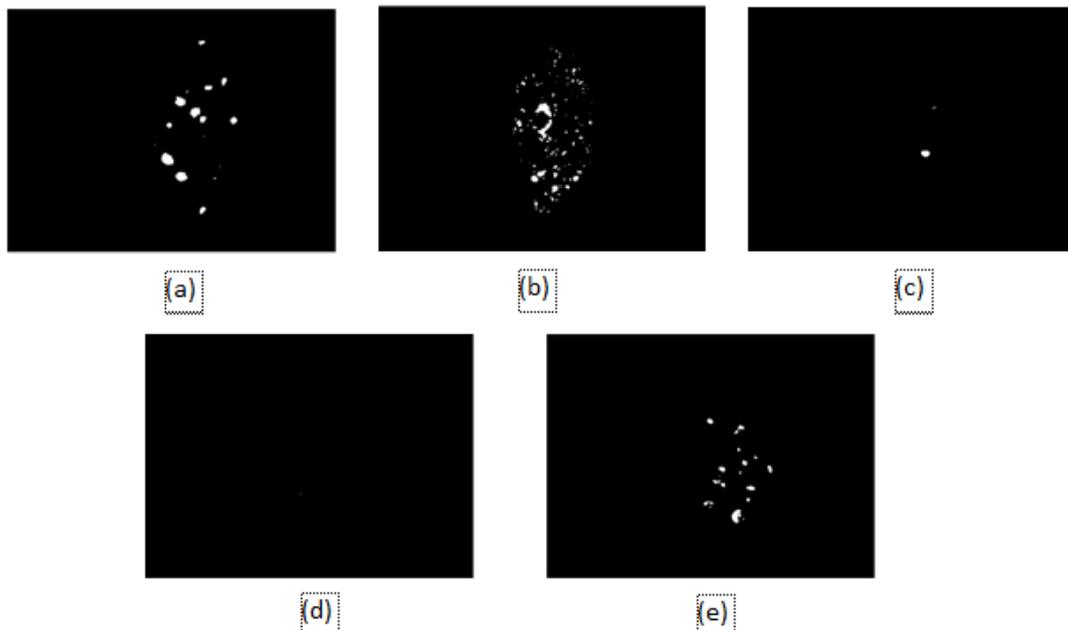
Gambar 5.12 Hasil proses K-means *clustering* dengan $K=2$, (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal, (e) daun lain

Citra biner dari hasil proses K-means *clustering* selanjutnya dilakukan proses *filling* objek untuk pengisian bagian citra yang berlubang (*holes*). Gambar 5.13 menunjukkan sampel citra hasil *filling* objek.



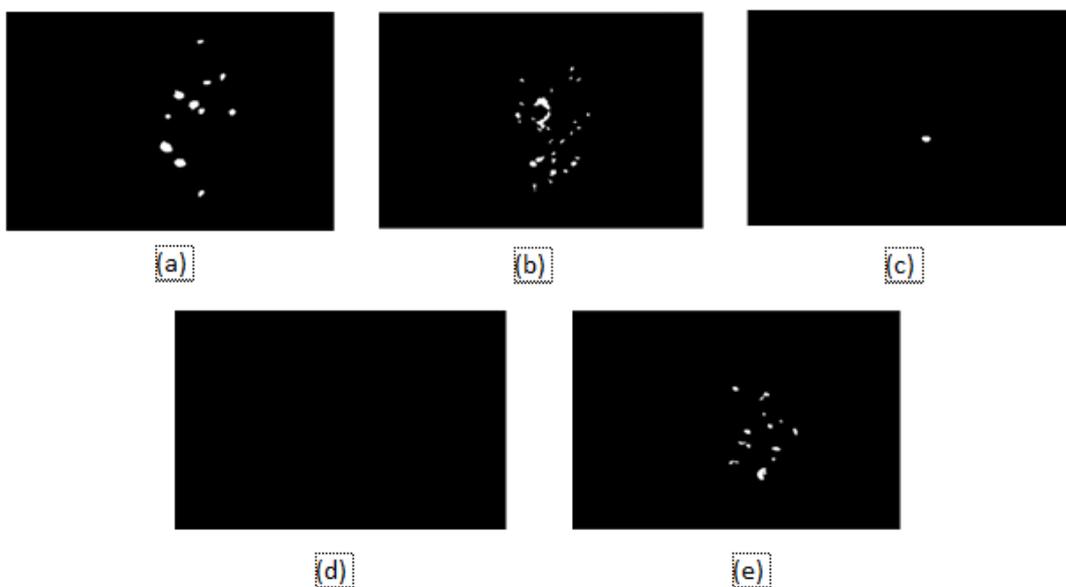
Gambar 5.13 Sampel daun kacang tanah dari *filling* objek (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal (e) daun lain

Kemudian akan dilakukan *subtraction* citra terhadap citra hasil *clustering* K-means dengan citra hasil *filling*. Gambar 5.14 menunjukkan citra hasil *subtraction*.

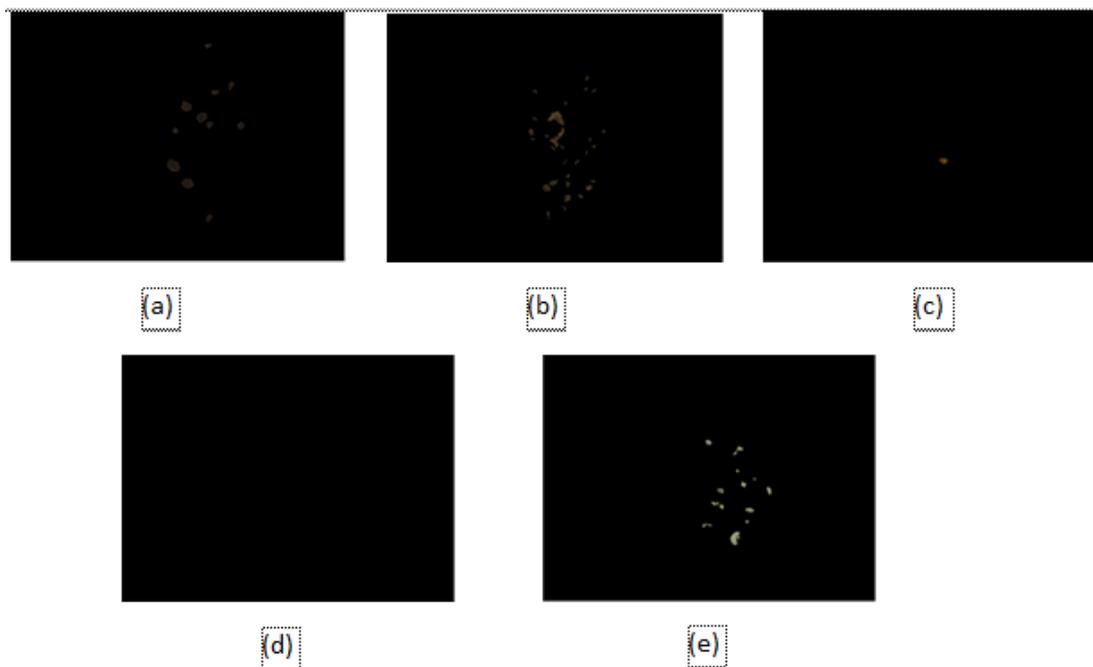


Gambar 5.14 Sampel daun kacang tanah dari proses *subtraction* (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal, (e) daun lain

Selanjutnya citra hasil *subtraction* akan diproses untuk menghilangkan objek dengan jumlah pixel yang kecil atau dianggap sebagai *noise*, yaitu dengan fungsi *bwareaopen*, objek yang dihilangkan yaitu objek yang mengandung kurang dari 10 piksel. Gambar 5.15 menunjukkan citra hasil *bwareaopen*. Citra hasil dari proses segmentasi diperlihatkan pada Gambar 5.16.



Gambar 5.15 Sampel dari proses *bwareaopen* pada citra daun kacang tanah (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal, (e) daun lain



Gambar 5.16 Sampel hasil dari segmentasi citra daun kacang tanah (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal, (e) daun lain



Gambar 5.17 Sampel hasil segmentasi citra daun kacang tanah kurang sempurna

Gambar 5.17 menunjukkan hasil segmentasi dari citra daun kacang tanah yang kurang sempurna, dimana bagian penyakit pada citra daun kacang tanah tidak tersegmentasi seluruhnya. Ketidaktepatan segmentasi pada citra daun kacang tanah ini dikarenakan adanya warna yang berbeda pada bagian penyakit satu dengan yang lain. Selain itu bisa juga disebabkan karena dimensi/ukuran penyakit yang terlalu kecil.

5.1.3 Ekstraksi Ciri

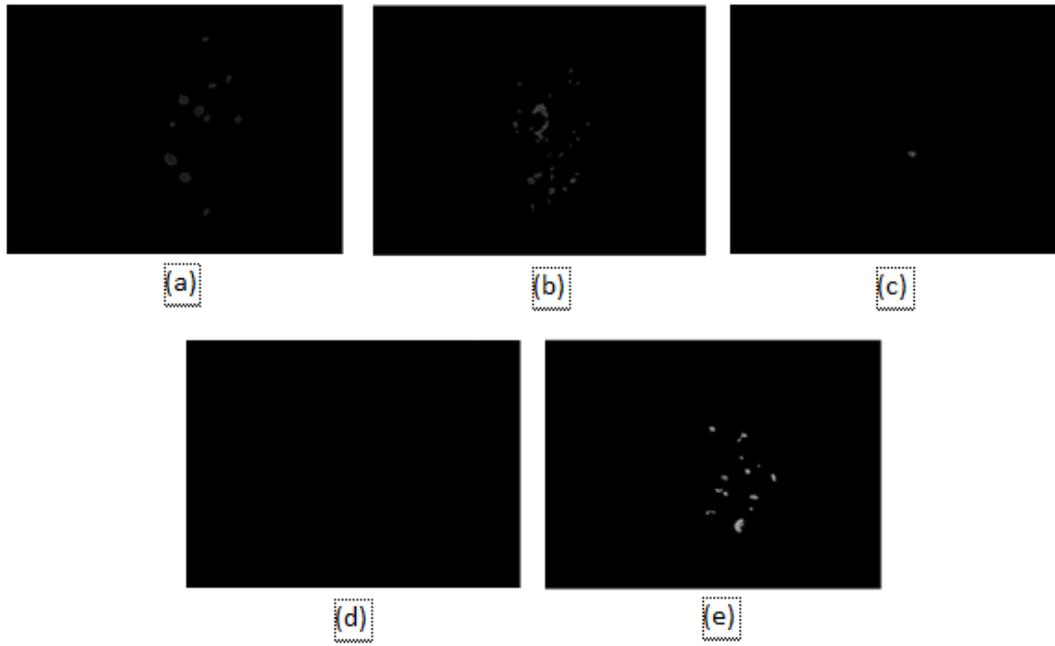
5.1.3.1 Ciri GLCM

GLCM adalah metode statistik orde kedua yang direpresentasikan dengan matriks korelasi dengan menghitung hubungan dua piksel dengan *distance* dan sudut tertentu. Penelitian ini menggunakan *distance* $d=1$ dan sudut $0^\circ, 45^\circ, 90^\circ$ dan 135° .

Proses yang digunakan untuk memperoleh ciri GLCM, yaitu :

1. Mengubah citra RGB hasil segmentasi menjadi *grayscale*.

Sebelum masuk ke dalam proses ekstraksi ciri tekstur menggunakan metode GLCM, citra hasil segmentasi dalam ruang warna RGB harus terlebih dahulu diubah ke dalam *grayscale*. Gambar 5.18 adalah sampel citra dalam *grayscale*.



Gambar 5.18 Sampel daun kacang tanah dalam grayscale (a) bercak daun, (b) karat daun, (c) bercak mata, (d) daun normal, (e) daun lain

2. Menyusun matriks kookurensi dengan menggunakan fungsi dari toolbox MATLAB, yaitu *graycomatrix* dengan 4 sudut orientasi, yaitu 0° , 45° , 90° dan 135° dan jarak $d=1$. Gambar 5.19 merupakan sampel hasil pembentukan matriks kookurensi.

```
glcm =
    9843     197         0         0         0         0         0         0
     197     739         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
```

(a)

```
glcm =
    9670     276         0         0         0         0         0         0
     275     657         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
         0         0         0         0         0         0         0         0
```

(b)

g1cm =

0.8920	0.0223	0	0	0	0	0	0	0	0	0
0.0222	0.0634	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0

(d)

Gambar 5.20 Sampel matriks normalisasi dengan sudut (a) 0°, (b) 45°, (c) 90° dan (d) 135°

4. Melakukan ekstraksi ciri GLCM dengan jumlah 11 ciri yang diekstraksi. Gambar 5.21 merupakan sampel dari hasil proses perhitungan ekstraksi ciri GLCM.

	1	2	3	4	5	6	7	8	9	10	11
1	0.8094	0.0359	0.9821	0.7699	0.4237	1.2222	2.1706	0.3988	3.4152	0.1547	0.0359
2	0.8157	0.0681	0.9659	0.4361	0.4303	1.1604	2.1291	0.3831	3.2222	0.2487	0.0681
3	0.9074	0.0251	0.9875	0.6325	0.2427	1.0735	2.0707	0.2254	3.5166	0.1172	0.0251
4	0.9339	0.0204	0.9898	0.5572	0.1846	1.0394	2.0472	0.1704	3.5940	0.0996	0.0204
5	0.8502	0.0429	0.9786	0.6060	0.3610	1.1403	2.1154	0.3313	3.3579	0.1769	0.0429
6	0.9493	0.0169	0.9916	0.5055	0.1482	1.0209	2.0347	0.1365	3.6547	0.0856	0.0169
7	0.9437	0.0111	0.9944	0.7540	0.1572	1.0371	2.0463	0.1495	3.6773	0.0612	0.0111
8	0.8826	0.0267	0.9866	0.7075	0.2913	1.1121	2.0960	0.2727	3.4803	0.1232	0.0267
9	0.6940	0.0875	0.9562	0.6131	0.6429	1.3549	2.2600	0.5822	3.1798	0.2968	0.0875
10	0.9329	0.0230	0.9885	0.4861	0.1873	1.0363	2.0457	0.1714	3.5797	0.1094	0.0230
11	0.9571	0.0130	0.9935	0.5702	0.1286	1.0141	2.0306	0.1196	3.6992	0.0692	0.0130
12	0.9155	0.0197	0.9902	0.6987	0.2228	1.0686	2.0675	0.2092	3.5642	0.0967	0.0197
13	0.9388	0.0206	0.9897	0.4960	0.1733	1.0309	2.0418	0.1590	3.6063	0.1005	0.0206
14	0.8885	0.0309	0.9845	0.6208	0.2832	1.0953	2.0852	0.2617	3.4573	0.1380	0.0309
15	0.9656	0.0148	0.9926	0.2563	0.1054	0.9988	2.0201	0.0952	3.7300	0.0769	0.0148
16	0.8635	0.0413	0.9794	0.5743	0.3356	1.1192	2.1022	0.3070	3.3753	0.1720	0.0413
17	0.8774	0.0343	0.9828	0.6163	0.3061	1.1083	2.0939	0.2823	3.4262	0.1495	0.0343
18	0.8771	0.0345	0.9827	0.6149	0.3068	1.1083	2.0940	0.2829	3.4249	0.1501	0.0345
19	0.8294	0.0424	0.9788	0.6737	0.3973	1.1771	2.1397	0.3679	3.3568	0.1755	0.0424

(a)

	1	2	3	4	5	6	7	8	9	10	11
1	0.7952	0.0507	0.9747	0.6769	0.4604	1.2233	2.1714	0.4253	3.3120	0.2004	0.0507
2	0.8070	0.0776	0.9612	0.3605	0.4455	1.1614	2.1298	0.3917	3.1862	0.2729	0.0776
3	0.9007	0.0325	0.9837	0.5212	0.2591	1.0728	2.0704	0.2366	3.4661	0.1434	0.0325
4	0.9291	0.0254	0.9873	0.4480	0.1959	1.0394	2.0472	0.1783	3.5596	0.1185	0.0254
5	0.8399	0.0543	0.9729	0.5011	0.3835	1.1402	2.1154	0.3459	3.2944	0.2109	0.0543
6	0.9454	0.0208	0.9896	0.3894	0.1571	1.0208	2.0347	0.1426	3.6276	0.1013	0.0208
7	0.9402	0.0153	0.9924	0.6578	0.1683	1.0361	2.0457	0.1577	3.6388	0.0791	0.0153
8	0.8719	0.0383	0.9808	0.5803	0.3184	1.1121	2.0958	0.2918	3.3987	0.1625	0.0383
9	0.6821	0.0979	0.9511	0.5736	0.6661	1.3617	2.2646	0.5983	3.1378	0.3204	0.0979
10	0.9274	0.0287	0.9856	0.3578	0.1990	1.0362	2.0458	0.1791	3.5451	0.1303	0.0287
11	0.9546	0.0157	0.9921	0.4752	0.1351	1.0142	2.0304	0.1242	3.6778	0.0809	0.0157
12	0.9085	0.0276	0.9862	0.5742	0.2416	1.0674	2.0670	0.2225	3.5040	0.1262	0.0276
13	0.9335	0.0264	0.9868	0.3547	0.1849	1.0308	2.0417	0.1667	3.5711	0.1218	0.0264
14	0.8777	0.0429	0.9785	0.4715	0.3077	1.0960	2.0848	0.2779	3.3844	0.1771	0.0429
15	0.9660	0.0146	0.9927	0.2608	0.1045	0.9987	2.0199	0.0944	3.7322	0.0760	0.0146
16	0.8542	0.0530	0.9735	0.4457	0.3552	1.1195	2.1007	0.3185	3.3142	0.2072	0.0530
17	0.8652	0.0476	0.9762	0.4678	0.3333	1.1080	2.0939	0.3003	3.3483	0.1914	0.0476
18	0.8702	0.0418	0.9791	0.5350	0.3227	1.1083	2.0942	0.2938	3.3795	0.1735	0.0418
19	0.8330	0.0395	0.9802	0.6935	0.3890	1.1741	2.1386	0.3616	3.3763	0.1665	0.0395

(b)

	1	2	3	4	5	6	7	8	9	10	11
1	0.8080	0.0378	0.9811	0.7573	0.4279	1.2213	2.1701	0.4017	3.4006	0.1608	0.0378
2	0.8205	0.0638	0.9681	0.4672	0.4212	1.1589	2.1279	0.3770	3.2415	0.2373	0.0638
3	0.9058	0.0276	0.9862	0.5906	0.2471	1.0725	2.0698	0.2279	3.4996	0.1262	0.0276
4	0.9327	0.0217	0.9891	0.5275	0.1875	1.0389	2.0471	0.1725	3.5846	0.1047	0.0217
5	0.8474	0.0464	0.9768	0.5723	0.3676	1.1396	2.1150	0.3354	3.3373	0.1876	0.0464
6	0.9490	0.0171	0.9914	0.4990	0.1488	1.0205	2.0347	0.1369	3.6530	0.0865	0.0171
7	0.9443	0.0113	0.9944	0.7479	0.1562	1.0367	2.0457	0.1484	3.6775	0.0617	0.0113
8	0.8805	0.0298	0.9851	0.6707	0.2976	1.1105	2.0951	0.2770	3.4570	0.1342	0.0298
9	0.6994	0.0808	0.9596	0.6429	0.6305	1.3551	2.2601	0.5745	3.2129	0.2807	0.0808
10	0.9306	0.0253	0.9873	0.4334	0.1924	1.0367	2.0457	0.1748	3.5645	0.1181	0.0253
11	0.9571	0.0132	0.9934	0.5600	0.1286	1.0145	2.0304	0.1195	3.6983	0.0701	0.0132
12	0.9152	0.0206	0.9897	0.6814	0.2242	1.0680	2.0669	0.2099	3.5570	0.1004	0.0206
13	0.9389	0.0206	0.9897	0.4985	0.1732	1.0312	2.0419	0.1590	3.6067	0.1002	0.0206
14	0.8881	0.0321	0.9839	0.6027	0.2845	1.0954	2.0844	0.2622	3.4499	0.1420	0.0321
15	0.9666	0.0139	0.9930	0.2913	0.1031	0.9986	2.0198	0.0935	3.7362	0.0733	0.0139
16	0.8637	0.0439	0.9781	0.5350	0.3358	1.1189	2.0993	0.3054	3.3626	0.1801	0.0439
17	0.8796	0.0328	0.9836	0.6304	0.3011	1.1067	2.0930	0.2784	3.4374	0.1443	0.0328
18	0.8778	0.0340	0.9830	0.6190	0.3053	1.1079	2.0937	0.2817	3.4282	0.1485	0.0340
19	0.8330	0.0381	0.9809	0.7074	0.3878	1.1757	2.1401	0.3614	3.3864	0.1620	0.0381

(c)

	1	2	3	4	5	6	7	8	9	10	11
1	0.8007	0.0446	0.9777	0.7156	0.4465	1.2233	2.1714	0.4156	3.3520	0.1823	0.0446
2	0.8064	0.0783	0.9609	0.3551	0.4464	1.1619	2.1298	0.3921	3.1840	0.2746	0.0783
3	0.8999	0.0333	0.9833	0.5090	0.2608	1.0738	2.0704	0.2377	3.4610	0.1461	0.0333
4	0.9289	0.0257	0.9872	0.4434	0.1964	1.0388	2.0472	0.1786	3.5583	0.1193	0.0257
5	0.8379	0.0565	0.9718	0.4807	0.3875	1.1403	2.1154	0.3484	3.2836	0.2172	0.0565
6	0.9454	0.0209	0.9895	0.3865	0.1573	1.0202	2.0347	0.1428	3.6270	0.1017	0.0209
7	0.9411	0.0144	0.9928	0.6778	0.1658	1.0375	2.0457	0.1558	3.6468	0.0754	0.0144
8	0.8726	0.0375	0.9812	0.5886	0.3167	1.1110	2.0958	0.2907	3.4035	0.1600	0.0375
9	0.6821	0.0979	0.9511	0.5736	0.6661	1.3617	2.2646	0.5983	3.1378	0.3204	0.0979
10	0.9262	0.0299	0.9850	0.3306	0.2012	1.0374	2.0458	0.1805	3.5389	0.1345	0.0299
11	0.9531	0.0173	0.9914	0.4241	0.1387	1.0149	2.0304	0.1267	3.6669	0.0872	0.0173
12	0.9103	0.0256	0.9872	0.6041	0.2370	1.0687	2.0670	0.2193	3.5178	0.1192	0.0256
13	0.9351	0.0247	0.9877	0.3954	0.1817	1.0312	2.0417	0.1646	3.5805	0.1158	0.0247
14	0.8805	0.0399	0.9800	0.5088	0.3018	1.0962	2.0848	0.2742	3.4010	0.1676	0.0399
15	0.9657	0.0148	0.9926	0.2495	0.1050	0.9987	2.0199	0.0947	3.7309	0.0770	0.0148
16	0.8506	0.0570	0.9715	0.4034	0.3619	1.1226	2.1007	0.3225	3.2961	0.2188	0.0570
17	0.8703	0.0419	0.9790	0.5313	0.3224	1.1080	2.0939	0.2934	3.3788	0.1741	0.0419
18	0.8678	0.0443	0.9778	0.5061	0.3278	1.1089	2.0942	0.2971	3.3650	0.1815	0.0443
19	0.8142	0.0605	0.9698	0.5315	0.4327	1.1728	2.1386	0.3908	3.2526	0.2282	0.0605

(d)

Gambar 5.21 Sampel dari ekstraksi ciri tekstur GLCM dengan sudut (a) 0°, (b) 45°, (c) 90° dan (d) 135°

Keterangan :

1 = ciri ASM	7 = ciri sum average
2 = ciri contrast	8 = ciri sum entropy
3 = ciri IDM	9 = ciri sum variance
4 = ciri correlation	10 = ciri difference entropy
5 = ciri entropy	11 = ciri difference variance
6 = ciri variance	

5.1.3.2 Ciri HSV

Pengambilan iri pada warna dilakukan dalam ruang HSV dengan ciri yang diambil, yaitu *mean* dari H, *mean* dari S dan *mean* dari V.

Dalam tahapan untuk memperoleh ciri dari warna ekstraksi HSV, citra daun kacang tanah RGB diubah menjadi HSV. Proses dari konversi gambar RGB ke HSV terdiri dari beberapa tahapan, yaitu

1. Menghitung nilai H, nilai S dan nilai V berdasarkan Persamaan (2-8) sampai dengan (2-12). Gambar 5.22 merupakan sampel hasil perhitungan data H, S dan V.

	246	247	248	249	250	251	252	253	254	255	256	257	258	259	260	261
150	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
151	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
152	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
153	0	0	0	0	0.0635	0.0655	0.0635	0.0313	0.0128	0.0256	0.0139	0.0533	0	0	0	0
154	0	0	0	0.0691	0	0	0	0	0	0.9762	0	0.0333	0.0778	0	0	0
155	0	0	0	0.0577	0.9792	0	0.9722	0	0	0	0	0	0.0455	0.0735	0	0
156	0	0	0	0.0625	0	0	0.9583	0.9583	0	0	0.9762	0.9815	0.0185	0.0238	0.0735	0
157	0	0.0913	0.0521	0.0370	0.0238	0	0.9583	0.9583	0.9583	0.9667	0.9722	0.9815	0	0.0167	0.0139	0.0606
158	0.0913	0.0294	0.0167	0.0208	0	0.0333	0	0.9583	0.9667	0.9583	0.9667	0.9762	0.0167	0.0167	0	0.0449
159	0	0.0111	0.0167	0.0185	0	0.0278	0.0278	0.9667	0.9583	0.9583	0.9583	0	0.0185	0.0303	0.0139	0.0400
160	0	0.0753	0.0312	0.0167	0	0	0	0	0.9667	0.9583	0.9722	0	0.0333	0.0167	0.0238	0.0889
161	0	0	0.0873	0	0.9833	0	0	0	0	0	0	0.0167	0.0278	0	0.0385	0
162	0	0	0	0.0833	0.0679	0.0417	0	0	0	0	0.0208	0.0303	0.0238	0.0645	0	0
163	0	0	0	0	0	0.0930	0.0507	0.0526	0.0625	0.0679	0.0294	0.0104	0.0619	0	0	0
164	0	0	0	0	0	0	0	0	0	0	0	0.0644	0	0	0	0
165	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
166	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
167	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

(a)

	246	247	248	249	250	251	252	253	254	255	256	257	258	259	260	261
149	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
150	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
151	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
152	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
153	0	0	0	0	0.6667	0.5385	0.4468	0.4000	0.3421	0.3171	0.3077	0.5102	0	0	0	0
154	0	0	0	0.6833	0.3250	0.2353	0.2000	0.2258	0.2424	0.2333	0.2188	0.2778	0.5660	0	0	0
155	0	0	0	0.5900	0.2353	0.2000	0.2069	0.2000	0.1765	0.2000	0.2414	0.2667	0.3235	0.5667	0	0
156	0	0	0	0.3902	0.2000	0.1786	0.1429	0.1379	0.1667	0.1818	0.2121	0.2727	0.2727	0.3500	0.5763	0
157	0	0.6774	0.3721	0.2500	0.2121	0.1563	0.1429	0.1429	0.1481	0.1613	0.1538	0.2500	0.2632	0.2778	0.3333	0.5593
158	0.6774	0.3953	0.2778	0.2424	0.1667	0.1351	0.1290	0.1333	0.1724	0.1429	0.1515	0.2188	0.2857	0.2941	0.3235	0.5000
159	0	0.3571	0.2941	0.2571	0.1667	0.1622	0.1714	0.1563	0.1379	0.1379	0.1538	0.2000	0.2571	0.3235	0.3333	0.5208
160	0	0.5536	0.3721	0.2778	0.2162	0.1714	0.1818	0.1875	0.1471	0.1250	0.2069	0.2258	0.2778	0.2941	0.3684	0.6818
161	0	0	0.6000	0.3556	0.2703	0.1765	0.1875	0.1875	0.1875	0.1714	0.1765	0.2632	0.3077	0.2703	0.5417	0
162	0	0	0	0.6462	0.5000	0.3077	0.1818	0.1818	0.1563	0.1818	0.2424	0.2821	0.3500	0.5536	0	0
163	0	0	0	0	0	0.6232	0.4510	0.4419	0.4615	0.4576	0.3778	0.3404	0.5303	0	0	0
164	0	0	0	0	0	0	0	0	0	0	0	0.6377	0	0	0	0
165	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
166	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
167	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

(b)

	246	247	248	249	250	251	252	253	254	255	256	257	258	259	260	261
148	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
149	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
150	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
151	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
152	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
153	0	0	0	0	0.2471	0.2039	0.1843	0.1569	0.1490	0.1608	0.1529	0.1922	0	0	0	0
154	0	0	0	0.2353	0.1569	0.1333	0.1176	0.1216	0.1294	0.1176	0.1255	0.1412	0.2078	0	0	0
155	0	0	0	0.2039	0.1333	0.1176	0.1137	0.1176	0.1333	0.1176	0.1137	0.1176	0.1333	0.2353	0	0
156	0	0	0	0.1608	0.1176	0.1098	0.1098	0.1137	0.1176	0.1294	0.1294	0.1294	0.1294	0.1569	0.2314	0
157	0	0.2431	0.1686	0.1412	0.1294	0.1255	0.1098	0.1098	0.1059	0.1216	0.1529	0.1412	0.1490	0.1412	0.1412	0.2314
158	0.2431	0.1686	0.1412	0.1294	0.1412	0.1451	0.1216	0.1176	0.1137	0.1098	0.1294	0.1255	0.1373	0.1333	0.1333	0.2039
159	0	0.1647	0.1333	0.1373	0.1412	0.1451	0.1373	0.1255	0.1137	0.1137	0.1020	0.1176	0.1373	0.1333	0.1412	0.1882
160	0	0.2196	0.1686	0.1412	0.1451	0.1373	0.1294	0.1255	0.1333	0.1255	0.1137	0.1216	0.1412	0.1333	0.1490	0.2588
161	0	0	0.2745	0.1765	0.1451	0.1333	0.1255	0.1255	0.1255	0.1373	0.1333	0.1490	0.1529	0.1451	0.1882	0
162	0	0	0	0.2549	0.2118	0.1529	0.1294	0.1294	0.1255	0.1294	0.1294	0.1529	0.1569	0.2196	0	0
163	0	0	0	0	0	0.2706	0.2000	0.1686	0.2039	0.2314	0.1765	0.1843	0.2588	0	0	0
164	0	0	0	0	0	0	0	0	0	0	0	0.2706	0	0	0	0
165	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
166	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
167	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

(c)

Gambar 5.22 Sampel hasil perhitungan (a) data H, (b) data S dan (c) data V

2. Menghitung nilai *mean* dengan menggunakan Persamaan (4-1) pada setiap elemen H, elemen S dan elemen V. Gambar 5.23 merupakan sampel dari hasil perhitungan *mean* nilai H, *mean* nilai S, *mean* nilai V.

12	13	14
0.2309	0.2018	0.1559
0.3892	0.1745	0.1346
0.2010	0.2513	0.1506
0.2452	0.2162	0.1420
0.0653	0.3576	0.1584
0.0837	0.3158	0.1486
0.0584	0.3665	0.1753
0.1271	0.4164	0.1801
0.0736	0.2934	0.1605
0.2316	0.3345	0.1519
0.0848	0.3542	0.1498
0.0894	0.3480	0.1698
0.1398	0.3081	0.1463
0.1048	0.3659	0.1627
0.1296	0.2765	0.1321
0.2814	0.3019	0.1542
0.1017	0.3277	0.1534
0.0579	0.3528	0.1631
0.3136	0.2461	0.1505

Gambar 5.23 Sampel hasil perhitungan nilai *mean* H, *mean* S dan *mean* V

Keterangan :

12 = ciri <i>mean</i> H
13 = ciri <i>mean</i> S
14 = ciri <i>mean</i> V

5.1.4 Klasifikasi

Dalam penelitian ini mengklasifikasikan penyakit pada citra daun kacang tanah menjadi lima kelas, yaitu kelas bercak daun, kelas karat daun, kelas bercak mata, kelas daun normal dan kelas daun lain. Metode klasifikasi yang digunakan adalah *Multiclass SVM*. Strategi *Multiclass SVM* yang digunakan adalah *Directed Acyclic Graph Support Vector Machine* (DAGSVM). Sebelum masuk dalam proses klasifikasi citra daun kacang tanah dibagi dalam data latih dan data uji dengan jumlah dataset yang dipakai 402 citra. Rincian data, yaitu 100 data kelas bercak daun, 100 data kelas karat daun, 72 data kelas bercak mata, 100 data kelas daun normal dan 30 data kelas daun lain. Pembagian seluruh data citra daun tanaman kacang tanah yang masing-masing telah diketahui label kelasnya menggunakan metode *holdout*, untuk dibagi menjadi dataset latih dan uji. Proporsi pembagian dataset untuk latih dan untuk uji, yaitu 70% sebagai dataset untuk latih dan 30% sebagai dataset untuk uji, yaitu dengan hasil 282 citra sebagai dataset untuk latih dan 120 citra sebagai dataset untuk uji.. Dengan rincian data untuk latih pada kelas bercak daun, karat daun dan daun normal masing-masing terdiri dari 70 data, untuk kelas bercak mata terdiri dari 51 data dan kelas daun lain terdiri dari 21 data. Rincian dataset untuk uji terdiri dari 30 data untuk kelas bercak daun, karat daun dan daun normal, untuk kelas

bercak mata terdiri dari 21 data dan kelas daun lain terdiri dari 9 data. Dalam tahapan proses klasifikasi dibagi menjadi dua, yaitu tahapan untuk pelatihan dan tahapan untuk pengujian.

5.1.4.1 Tahap Pelatihan

Dalam tahap pelatihan, dataset yang dipakai adalah menggunakan dataset untuk latih. Sampel dataset pelatihan dalam proses ini adalah data hasil ciri dengan HSV dan ciri dengan GLCM menggunakan sudut 0° dengan jarak $d=1$ piksel serta menggunakan kernel *polynomial*. Data yang digunakan terdiri dari 10 sampel citra daun kacang tanah. Tabel 5.1 merupakan sampel data ekstraksi ciri beserta label kelasnya.

Tabel 5.1 Ekstraksi ciri data latih

Data ke-	f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Actual Class
1	0.8094	0.0359	0.9821	0.7699	0.4237	1.2222	2.1706	0.3988	3.4152	0.1547	0.0359	0.2309	0.2018	0.1559	1
2	0.8157	0.0681	0.9659	0.4361	0.4303	1.1604	2.1291	0.3831	3.2222	0.2487	0.0681	0.3892	0.1745	0.1346	1
3	0.8583	0.0529	0.9795	0.7233	0.3939	1.2152	2.1474	0.3531	3.5492	0.1761	0.0529	0.1018	0.4538	0.2410	2
4	0.9531	0.0294	0.9913	0.6535	0.1602	1.0652	2.0540	0.1426	3.7936	0.0850	0.0294	0.1464	0.5672	0.2699	2
5	0.3643	0.2420	0.9128	0.6650	1.3377	2.5452	2.9825	1.1315	4.6292	0.5096	0.2420	0.1080	0.5925	0.2587	3
6	0.4132	0.1422	0.9460	0.8971	1.3284	3.1037	3.1392	1.2118	6.3356	0.3648	0.1422	0.1138	0.5811	0.3149	3
7	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4
8	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4
9	0.9658	0.0740	0.9935	0.7910	0.1334	1.2395	2.0931	0.1210	4.5231	0.0612	0.0740	0.2074	0.2743	0.4967	5
10	0.9865	0.0258	0.976	0.8131	0.0554	1.0753	2.0378	0.0528	4.1911	0.0244	0.0258	0.1865	0.3187	0.4965	5

Dalam proses pelatihan dilakukan dengan cara membangun $N(N-1)/2$ buah model klasifikasi. Proses pelatihan terdiri dari 10 buah model klasifikasi, dengan perhitungan

$$\begin{aligned}
 \text{Model Klasifikasi} &= \frac{N(N-1)}{2} \\
 &= \frac{5(5-1)}{2} \\
 &= 10
 \end{aligned}$$

Model klasifikasi 1

Tabel 5.2 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 1. Data yang diberi label 1 merupakan data yang termasuk dalam *actual class 1* dan data yang diberi label -1 merupakan data yang termasuk dalam *actual class 5*.

Tabel 5.2 Data yang dilatih pada model klasifikasi 1

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'1'	Actual Class
0.8094	0.0359	0.9821	0.7699	0.4237	1.2222	2.1706	0.3988	3.4152	0.1547	0.0359	0.2309	0.2018	0.1559	1	1
0.8157	0.0681	0.9659	0.4361	0.4303	1.1604	2.1291	0.3831	3.2222	0.2487	0.0681	0.3892	0.1745	0.1346	1	1
0.9658	0.0740	0.9935	0.7910	0.1334	1.2395	2.0931	0.1210	4.5231	0.0612	0.0740	0.2074	0.2743	0.4967	-1	5
0.9865	0.0258	0.976	0.8131	0.0554	1.0753	2.0378	0.0528	4.1911	0.0244	0.0258	0.1865	0.3187	0.4965	-1	5

Hasil dari tahapan pelatihan, yaitu nilai *alpha* dan bias yang nantinya akan digunakan dalam proses pengujian. Tabel 5.3 menunjukkan nilai *alpha* dan *bias* yang optimal.

Tabel 5.3 Nilai *alpha* dan *bias* model klasifikasi 1

<i>alpha 1</i>	1
<i>alpha 2</i>	1
<i>alpha 3</i>	1
<i>alpha 4</i>	1
<i>bias</i>	1.1492

Model Klasifikasi 2

Data yang digunakan dalam model klasifikasi 2 merupakan data latih dengan *actual class* 1 diberi label 1 dan *actual class* 4 diberi label -1. Tabel 5.4 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 2.

Tabel 5.4 Data yang dilatih pada model klasifikasi 2

f'1	f'2	f'3	f'4	f'5	f'6	f'7	f'8	f'9	f'10	f'11	f'12	f'13	f'14	Kelas MK'2	Actual Class
0.8094	0.0359	0.9821	0.7699	0.4237	1.2222	2.1706	0.3988	3.4152	0.1547	0.0359	0.2309	0.2018	0.1559	1	1
0.8157	0.0681	0.9659	0.4361	0.4303	1.1604	2.1291	0.3831	3.2222	0.2487	0.0681	0.3892	0.1745	0.1346	1	1
0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	4
0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	4

Hasil *alpha* dan *bias* yang didapatkan dari proses pelatihan pada model klasifikasi 2 diperlihatkan dengan Tabel 5.5.

Tabel 5.5 *alpha* dan *bias* model klasifikasi 2

<i>alpha 1</i>	0.7241
<i>alpha 2</i>	0.4878
<i>alpha 3</i>	0.6060
<i>alpha 4</i>	0.6060
<i>bias</i>	2.3389

Model Klasifikasi 3

Tabel 5.6 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 3. Data yang diberi label 1 merupakan data yang termasuk dalam *actual class* 1 dan data yang diberi label -1 merupakan data yang termasuk dalam *actual class* 3.

Tabel 5.6 Data yang dilatih pada model klasifikasi 3

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'3'	Actual Class
0.8094	0.0359	0.9821	0.7699	0.4237	1.2222	2.1706	0.3988	3.4152	0.1547	0.0359	0.2309	0.2018	0.1559	1	1
0.8157	0.0681	0.9659	0.4361	0.4303	1.1604	2.1291	0.3831	3.2222	0.2487	0.0681	0.3892	0.1745	0.1346	1	1
0.3643	0.2420	0.9128	0.6650	1.3377	2.5452	2.9825	1.1315	4.6292	0.5096	0.2420	0.1080	0.5925	0.2587	-1	3
0.4132	0.1422	0.9460	0.8971	1.3284	3.1037	3.1392	1.2118	6.3356	0.3648	0.1422	0.1138	0.5811	0.3149	-1	3

Tabel 5.7 Nilai *alpha* dan *bias* model klasifikasi 3

<i>alpha 1</i>	0.6060
<i>alpha 2</i>	0.6589
<i>alpha 3</i>	0.6660
<i>alpha 4</i>	0.6880
<i>bias</i>	1.7113

Model Klasifikasi 4

Data yang digunakan dalam model klasifikasi 4 merupakan data latih dengan *actual class* 1 diberi label 1 dan *actual class* 2 diberi label -1. Tabel 5.8 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 4.

Tabel 5.8 Data yang dilatih pada model klasifikasi 4

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'4'	Actual Class
0.8094	0.0359	0.9821	0.7699	0.4237	1.2222	2.1706	0.3988	3.4152	0.1547	0.0359	0.2309	0.2018	0.1559	1	1
0.8157	0.0681	0.9659	0.4361	0.4303	1.1604	2.1291	0.3831	3.2222	0.2487	0.0681	0.3892	0.1745	0.1346	1	1
0.8583	0.0529	0.9795	0.7233	0.3939	1.2152	2.1474	0.3531	3.5492	0.1761	0.0529	0.1018	0.4538	0.2410	-1	2
0.9531	0.0294	0.9913	0.6535	0.1602	1.0652	2.0540	0.1426	3.7936	0.0850	0.0294	0.1464	0.5672	0.2699	-1	2

Tabel 5.9 Nilai *alpha* dan *bias* model klasifikasi 4

<i>alpha 1</i>	1
<i>alpha 2</i>	1
<i>alpha 3</i>	1
<i>alpha 4</i>	1
<i>bias</i>	36.3995

Model Klasifikasi 5

Data yang digunakan dalam model klasifikasi 5 merupakan data latih dengan *actual class* 2 diberi label 1 dan *actual class* 5 diberi label -1. Tabel 5.10 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 5.

Tabel 5.10 Data yang dilatih pada model klasifikasi 5

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'5'	Actual Class
0.8583	0.0529	0.9795	0.7233	0.3939	1.2152	2.1474	0.3531	3.5492	0.1761	0.0529	0.1018	0.4538	0.2410	1	2
0.9531	0.0294	0.9913	0.6535	0.1602	1.0652	2.0540	0.1426	3.7936	0.0850	0.0294	0.1464	0.5672	0.2699	1	2
0.9658	0.0740	0.9935	0.7910	0.1334	1.2395	2.0931	0.1210	4.5231	0.0612	0.0740	0.2074	0.2743	0.4967	-1	5
0.9865	0.0258	0.976	0.8131	0.0554	1.0753	2.0378	0.0528	4.1911	0.0244	0.0258	0.1865	0.3187	0.4965	-1	5

Tabel 5.11 Nilai *alpha* dan *bias* model klasifikasi 5

<i>alpha 1</i>	1
<i>alpha 2</i>	1
<i>alpha 3</i>	1
<i>alpha 4</i>	1
<i>bias</i>	-32.0227

Model Klasifikasi 6

Data yang digunakan dalam model klasifikasi 6 merupakan data latih dengan *actual class 2* diberi label 1 dan *actual class 4* diberi label -1. Tabel 5.12 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 6.

Tabel 5.12 Data yang dilatih pada model klasifikasi 6

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'6'	Actual Class
0.8583	0.0529	0.9795	0.7233	0.3939	1.2152	2.1474	0.3531	3.5492	0.1761	0.0529	0.1018	0.4538	0.2410	1	2
0.9531	0.0294	0.9913	0.6535	0.1602	1.0652	2.0540	0.1426	3.7936	0.0850	0.0294	0.1464	0.5672	0.2699	1	2
0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	4
0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	4

Tabel 5.13 Nilai *alpha* dan *bias* optimal model klasifikasi 6

<i>alpha 1</i>	0.4129
<i>alpha 2</i>	0.9067
<i>alpha 3</i>	0.6598
<i>alpha 4</i>	0.6598
<i>bias</i>	11.7338

Model Klasifikasi 7

Data yang digunakan dalam model klasifikasi 7 merupakan data latih dengan *actual class 2* diberi label 1 dan *actual class 3* diberi label -1. Tabel 5.14 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 7.

Tabel 5.14 Data yang dilatih pada model klasifikasi 7

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'7'	Actual Class
0.8583	0.0529	0.9795	0.7233	0.3939	1.2152	2.1474	0.3531	3.5492	0.1761	0.0529	0.1018	0.4538	0.2410	1	2
0.9531	0.0294	0.9913	0.6535	0.1602	1.0652	2.0540	0.1426	3.7936	0.0850	0.0294	0.1464	0.5672	0.2699	1	2
0.3643	0.2420	0.9128	0.6650	1.3377	2.5452	2.9825	1.1315	4.6292	0.5096	0.2420	0.1080	0.5925	0.2587	-1	3
0.4132	0.1422	0.9460	0.8971	1.3284	3.1037	3.1392	1.2118	6.3356	0.3648	0.1422	0.1138	0.5811	0.3149	-1	3

Tabel 5.15 Nilai *alpha* dan *bias* optimal model klasifikasi 7

<i>alpha 1</i>	0.8203
<i>alpha 2</i>	0.7696
<i>alpha 3</i>	0.8004
<i>alpha 4</i>	0.7895
<i>bias</i>	3.3689

Model Klasifikasi 8

Data yang digunakan dalam model klasifikasi 8 merupakan data latih dengan *actual class* 3 diberi label 1 dan *actual class* 5 diberi label -1. Tabel 5.16 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 8.

Tabel 5.16 Data yang dilatih pada model klasifikasi 8

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'8'	Actual Class
0.3643	0.2420	0.9128	0.6650	1.3377	2.5452	2.9825	1.1315	4.6292	0.5096	0.2420	0.1080	0.5925	0.2587	1	3
0.4132	0.1422	0.9460	0.8971	1.3284	3.1037	3.1392	1.2118	6.3356	0.3648	0.1422	0.1138	0.5811	0.3149	1	3
0.9658	0.0740	0.9935	0.7910	0.1334	1.2395	2.0931	0.1210	4.5231	0.0612	0.0740	0.2074	0.2743	0.4967	-1	5
0.9865	0.0258	0.976	0.8131	0.0554	1.0753	2.0378	0.0528	4.1911	0.0244	0.0258	0.1865	0.3187	0.4965	-1	5

Tabel 5.17 Nilai *alpha* dan *bias* model klasifikasi 8

<i>alpha 1</i>	0.6424
<i>alpha 2</i>	0.6628
<i>alpha 3</i>	0.6929
<i>alpha 4</i>	0.6122
<i>bias</i>	-7.9882

Model Klasifikasi 9

Data yang digunakan dalam model klasifikasi 9 merupakan data latih dengan *actual class* 3 diberi label 1 dan *actual class* 4 diberi label -1. Tabel 5.18 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 9.

Tabel 5.18 Data yang dilatih pada model klasifikasi 9

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK'9'	Actual Class
0.3643	0.2420	0.9128	0.6650	1.3377	2.5452	2.9825	1.1315	4.6292	0.5096	0.2420	0.1080	0.5925	0.2587	1	3
0.4132	0.1422	0.9460	0.8971	1.3284	3.1037	3.1392	1.2118	6.3356	0.3648	0.1422	0.1138	0.5811	0.3149	1	3
0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	4
0	0	0	0	0	0	0	0	0	0	0	0	0	0	-1	4

Tabel 5.19 Nilai alpha dan bias optimal model klasifikasi 9

<i>alpha 1</i>	0.9981
<i>alpha 2</i>	0.9062
<i>alpha 3</i>	0.9521
<i>alpha 4</i>	0.9521
<i>bias</i>	-0.3353

Model Klasifikasi 10

Data yang digunakan dalam model klasifikasi 10 merupakan data latih dengan *actual class* 4 diberi label 1 dan *actual class* 5 diberi label -1. Tabel 5.20 menunjukkan data yang digunakan untuk proses pelatihan pada model klasifikasi 10.

Tabel 5.20 Data yang dilatih pada model klasifikasi 10

f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Kelas MK '10'	Actual Class
0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	4
0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	4
0.9658	0.0740	0.9935	0.7910	0.1334	1.2395	2.0931	0.1210	4.5231	0.0612	0.0740	0.2074	0.2743	0.4967	-1	5
0.9865	0.0258	0.976	0.8131	0.0554	1.0753	2.0378	0.0528	4.1911	0.0244	0.0258	0.1865	0.3187	0.4965	-1	5

Tabel 5.21 Nilai alpha dan bias model klasifikasi 10

<i>alpha 1</i>	0.7649
<i>alpha 2</i>	0.7649
<i>alpha 3</i>	0.2669
<i>alpha 4</i>	1.2629
<i>bias</i>	-38.9806

5.1.4.2 Tahap Pengujian

Dalam tahap pengujian, data yang digunakan adalah dataset untuk uji. Sampel dataset pengujian yang dipakai pada proses ini merupakan nilai ciri dari HSV serta ciri dari GLCM dengan sudut 0° dengan jarak $d=1$ piksel serta menggunakan kernel *polynomial*. Data yang

digunakan terdiri dari 5 sampel citra daun kacang tanah. Tabel 5.22 merupakan sampel data ekstraksi ciri beserta label kelasnya.

Tabel 5.22 Hasil ekstraksi ciri data uji

Data ke-	f'1'	f'2'	f'3'	f'4'	f'5'	f'6'	f'7'	f'8'	f'9'	f'10'	f'11'	f'12'	f'13'	f'14'	Actual Class
1	0.9184	0.0273	0.9864	0.5042	0.2202	1.0531	2.0566	0.2013	3.5251	0.1252	0.0273	0.1274	0.3148	0.1441	1
2	0.9369	0.0181	0.9928	0.7164	0.1857	1.0575	2.0568	0.1710	3.6658	0.0760	0.0181	0.1049	0.4377	0.2109	2
3	0.8500	0.0427	0.9835	0.8241	0.4023	1.2791	2.1828	0.3683	3.7347	0.1487	0.0427	0.0978	0.5465	0.2749	3
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	4
5	0.9498	0.1034	0.9905	0.7481	0.1834	1.2806	2.1091	0.1681	4.4848	0.0913	0.1034	0.2154	0.2665	0.4162	5

Perhitungan data pengujian dilakukan dengan menggunakan persamaan (2-26). Data uji dilakukan pengujian pada *node* 1, nilai $sign(f(x))$ data uji ke 1, 2, 3 dan 5 di *node* 1 adalah -1 maka data bergerak ke *node* 2, sedangkan data uji ke 4 nilainya +1, maka data bergerak ke *node* 3. Selanjutnya karena nilai $sign(f(x))$ data uji ke 1 dan 3 di *node* 2 adalah +1, maka data bergerak ke *node* 5, sedangkan data uji ke 2 dan 5 karena nilainya -1, maka data bergerak ke *node* 5, data uji ke 5 di *node* 2 nilainya -1, maka data bergerak ke *node* 4, data uji ke 4 di *node* 3 nilainya adalah -1, maka data bergerak ke *node* 5. Selanjutnya karena nilai $sign(f(x))$ data uji ke 2 dan 5 di *node* 4 nilainya adalah -1, maka data bergerak ke *node* 7, data uji ke 1 di *node* 5 nilainya adalah +1, maka data bergerak ke *node* 9, data uji ke 3 dan 4 di *node* 5 nilainya adalah -1, maka data bergerak ke *node* 8. Selanjutnya nilai $sign(f(x))$ data uji ke 2 di *node* 7 nilainya -1, maka data uji tersebut termasuk kelas 5 dengan label daun lain. Data uji ke 5 di *node* 7 nilainya adalah +1, maka data uji tersebut termasuk kelas 4 dengan label daun normal. Data uji ke 3 di *node* 8 nilainya +1, maka data uji tersebut masuk di kelas 3 dengan label bercak mata. Data uji ke 4 di *node* 8 nilainya adalah -1, maka data uji tersebut masuk pada kelas 4 dengan label daun normal. Data uji ke 1 di *node* 9 nilainya adalah +1, maka data uji tersebut masuk pada kelas 2 dengan label karat daun. Tabel 5.23 menunjukkan hasil pengujian di *node* 1. Tabel 5.24 menunjukkan hasil pengujian di *node* 2. Tabel 5.25 menunjukkan hasil pengujian di *node* 3. Tabel 5.26 menunjukkan hasil pengujian di *node* 4. Tabel 5.27 menunjukkan hasil pengujian di *node* 5. Tabel 5.28 menunjukkan hasil pengujian di *node* 6. Tabel 5.29 menunjukkan hasil pengujian di *node* 7. Tabel 5.30 menunjukkan hasil pengujian di *node* 8. Tabel 5.31 menunjukkan hasil pengujian di *node* 9. Tabel 5.32 menunjukkan hasil pengujian di *node* 10.

Tabel 5.23 Hasil pengujian di node 1

data ke-	$f(x)$ node 1	$sign(f(x))$	node berikutnya
1	-61.7287	-1	2
2	-109.466	-1	2
3	-4.39E+03	-1	2
4	5.42E+03	1	3
5	-89.8587	-1	2

Tabel 5.24 Hasil pengujian di node 2

data ke-	$f(x)$ node 3	$sign(f(x))$	node berikutnya
1	10.8722	1	5
2	-36.3319	-1	4
3	599.4972	1	5
5	-160.655	-1	4

Tabel 5.25 Hasil pengujian di node 3

data ke-	$f(x)$ node 2	$sign(f(x))$	node berikutnya
4	-48.5061	-1	5

Tabel 5.26 Hasil pengujian di node 4

data ke-	$f(x)$ node 4	$sign(f(x))$	node berikutnya
2	-32.5285	-1	7
5	-43.7922	-1	7

Tabel 5.27 Hasil pengujian di node 5

data ke-	$f(x)$ node 5	$sign(f(x))$	node berikutnya
1	40.7239	1	9
3	-100.443	-1	8
4	-49.8411	-1	8

Tabel 5.28 Hasil pengujian di node 6

data ke-	$f(x)$ node 6	$sign(f(x))$	node berikutnya
-	-	-	-

Tabel 5.29 Hasil pengujian di node 7

data ke-	$f(x)$ node 7	$sign(f(x))$	label kelas
2	-42.4226	-1	Daun Lain
5	20.1501	1	Daun Normal

Tabel 5.30 Hasil pengujian di node 8

data ke-	$f(x)$ node 8	$sign(f(x))$	label kelas
3	112.8716	1	Bercak Mata
4	-77.9095	-1	Daun Normal

Tabel 5.31 Hasil pengujian di node 9

data ke-	$f(x)$ node 9	$sign(f(x))$	label kelas
1	66.3286	1	Karat Daun

Tabel 5.32 Hasil pengujian di node 10

data ke-	$f(x)$ node 10	$sign(f(x))$	label kelas
1	-	-	-

5.2 Hasil Penelitian dan Pembahasan

Pada bagian ini menjelaskan performansi dari sistem klasifikasi penyakit daun tanaman kacang tanah dengan menggunakan metode *Multiclass SVM* dengan strategi *DAGSVM* dengan *input* berupa ciri tekstur *GLCM* dan ciri warna *HSV*. Perhitungan performansi sistem klasifikasi menggunakan *confusion matrix* sebagai alat perhitungannya. *Confusion matrix* ditampilkan dengan nilai dalam TP, FP, TN dan FN untuk mengetahui parameter performansi dari sistem klasifikasi yang diuji dalam penelitian ini, yaitu akurasi, sensitivitas, dan spesifisitas.

5.2.1 Pengujian akurasi, sensitivitas dan spesifisitas

Analisis performansi klasifikasi penyakit daun tanaman kacang tanah pada penelitian ini yaitu dengan hasil uji coba ketepatan klasifikasi yang dilihat berdasarkan akurasi,

sensitivitas dan spesifisitas. Pada penelitian ini digunakan tiga skenario percobaan, skenario pertama, yaitu klasifikasi dengan menggunakan metode M-SVM strategi DAGSVM menggunakan *input* ciri GLCM, skenario kedua, yaitu klasifikasi menggunakan *input* ciri HSV dan pada skenario ketiga, yaitu klasifikasi dengan menggunakan metode M-SVM strategi DAGSVM menggunakan kombinasi ciri GLCM dan ciri HSV. Metode klasifikasi *Multiclass* SVM dengan strategi DAGSVM pada penelitian ini membandingkan penggunaan tiga jenis kernel, yaitu linear, *polynomial* dan RBF. Tujuannya adalah untuk mendapatkan fungsi kernel yang paling optimal untuk diterapkan dalam klasifikasi penyakit daun kacang tanah.

5.2.1.1 Pengujian performansi klasifikasi penyakit daun kacang tanah dengan M-SVM strategi DAGSVM menggunakan *input* ciri GLCM

Pada skenario percobaan pertama digunakan ekstraksi ciri GLCM sebagai *input* dalam proses klasifikasi dengan menggunakan metode M-SVM strategi DAGSVM. Skenario percobaan ini dilakukan untuk mengetahui performansi sistem klasifikasi penyakit daun tanaman kacang tanah berdasarkan karakteristik tekstur dari penyakit daun kacang tanah. Tabel 5.33 adalah hasil persentase akurasi, sensitivitas dan spesifisitas dari hasil performansi sistem klasifikasi dengan menggunakan kernel *polynomial* dengan *input* ciri tekstur GLCM dengan sudut 0° , 45° , 90° dan 135° pada penelitian ini.

Tabel 5.33 Performansi kinerja klasifikasi untuk kernel *polynomial* dengan *input* ciri GLCM

No	Sudut	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	0°	Bercak Daun	19	80	10	11	82.5	63.3	88.9
2.		Karat Daun	0	76	14	30	63.3	0	83.3
3.		Bercak Mata	13	66	33	8	65.8	61.9	66.7
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	0	111	0	9	92.5	0	100
1.	45°	Bercak Daun	19	80	10	11	82.5	63.3	88.9
2.		Karat Daun	0	69	21	30	57.5	0	76.7
3.		Bercak Mata	7	53	32	14	50	33.3	67.7
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	1	111	0	8	93.3	11.1	100
1.	90°	Bercak Daun	18	84	6	12	85	60	93.3
2.		Karat Daun	1	71	19	29	60	33.3	78.9
3.		Bercak Mata	10	64	35	11	61.7	47.6	64.6
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	1	111	0	8	93.3	11.1	100
1.	135°	Bercak Daun	20	78	12	10	81.7	66.7	86.7
2.		Karat Daun	0	79	11	30	65.8	0	87.8

No	Sudut	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
3.		Bercak Mata	11	66	33	10	64.2	52.4	66.7
4.		Daun Normal	30	87	3	0	97.5	100	96.7
5.		Daun Lain	0	111	0	9	92.5	0	100

Contoh perhitungan nilai akurasi, nilai sensitivitas dan nilai spesifisitas dengan data uji sistem klasifikasi *Multiclass SVM* dengan strategi DAGSVM dengan *input* berupa ciri tekstur GLCM dengan sudut 0° pada kelas bercak daun adalah sebagai berikut:

$$TP = 19$$

$$TN = 80$$

$$FP = 10$$

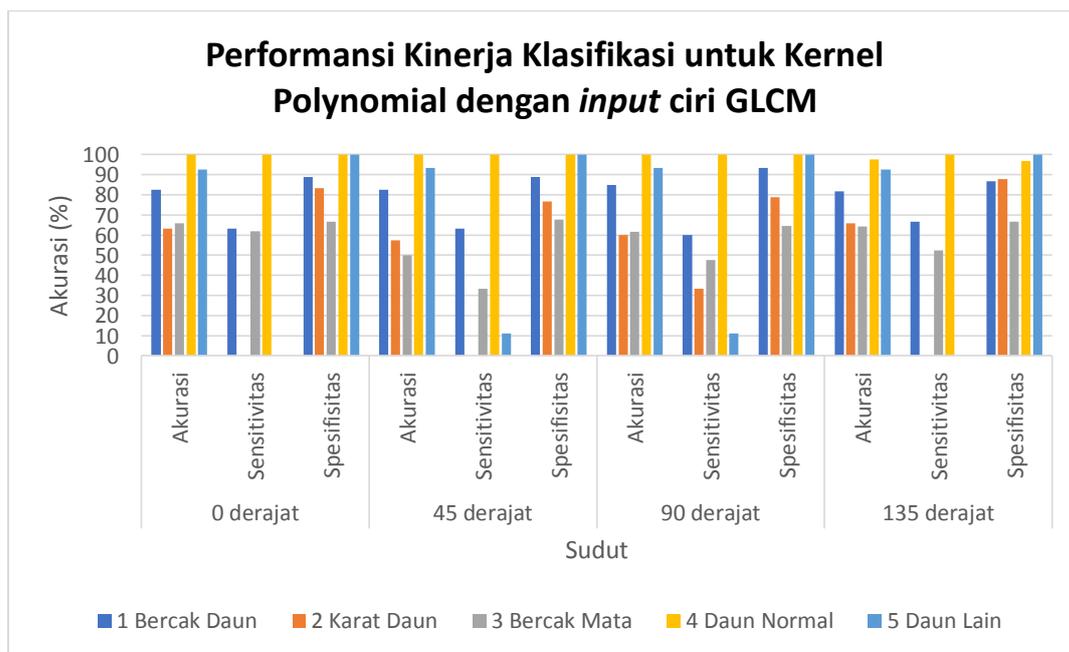
$$FN = 11$$

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} = \frac{19 + 80}{19 + 80 + 10 + 11} = \frac{99}{120} \times 100\% = 82.5\%$$

$$Sensitivitas = \frac{TP}{TP + FN} = \frac{19}{19 + 11} = \frac{19}{30} \times 100\% = 63.3\%$$

$$Spesifisitas = \frac{TN}{TN + FP} = \frac{80}{80 + 10} = \frac{80}{90} \times 100\% = 88.8\%$$

Grafik hasil persentase akurasi, sensitivitas dan spesifisitas dari data uji dengan kernel *polynomial* dengan *input* ciri GLCM ditunjukkan pada Gambar 5.24.



Gambar 5.24 Grafik hasil performansi klasifikasi untuk kernel polynomial dengan input ciri GLCM

Berdasarkan Tabel 5.33 dan Gambar 5.24 menunjukkan bahwa hasil akurasi, tertinggi pada klasifikasi penyakit daun tanaman kacang tanah dengan menggunakan *input* ciri

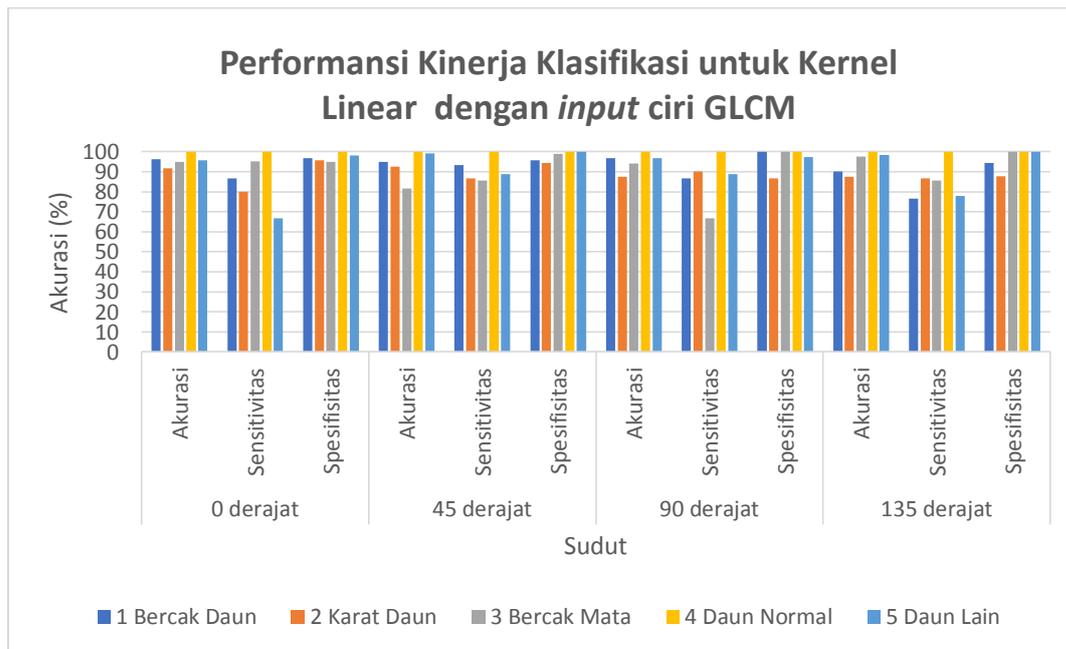
GLCM dan diklasifikasikan menggunakan metode M-SVM dengan strategi DAGSVM dengan kernel *polynomial*, yaitu dengan menggunakan jarak ketetanggaan piksel $d=1$ dan sudut GLCM 90° dengan nilai akurasi 85%, sensitivitas 60% dan spesifisitas 93.3% untuk kelas bercak daun; nilai akurasi 60%, sensitivitas 33.3% dan spesifisitas 78.9% untuk kelas karat daun; nilai akurasi 61.7%, sensitivitas 47.6% dan spesifisitas 64.6% untuk kelas bercak mata; nilai akurasi 100%, sensitivitas 100% dan spesifisitas 100% untuk kelas daun normal; nilai akurasi 93.3%, sensitivitas 11.1% dan spesifisitas 100% untuk kelas daun lain.

Tabel 5.34 menunjukkan hasil persentase akurasi, sensitivitas, spesifisitas dari hasil peformansi sistem klasifikasi dengan menggunakan kernel linear dengan *input* hasil ekstraksi ciri tekstur GLCM dengan sudut 0° , 45° , 90° dan 135° pada penelitian ini.

Tabel 5.34 Performansi kinerja klasifikasi untuk kernel linear dengan input ciri GLCM

No	Sudut	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	0°	Bercak Daun	26	87	3	4	94.2	86.7	96.7
2.		Karat Daun	24	86	4	6	91.7	80	95.6
3.		Bercak Mata	20	94	5	1	95	95.2	94.9
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	6	109	2	3	95.8	66.7	98.2
1.	45°	Bercak Daun	28	86	4	2	95	93.3	95.6
2.		Karat Daun	26	85	5	4	92.5	86.7	94.4
3.		Bercak Mata	18	98	1	3	81.7	85.7	98.9
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	8	111	0	1	99.2	88.9	100
1.	90°	Bercak Daun	26	90	0	4	96.7	86.7	100
2.		Karat Daun	27	78	12	3	87.5	90	86.7
3.		Bercak Mata	14	99	0	7	94.2	66.7	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	8	108	3	1	96.7	88.9	97.3
1.	135°	Bercak Daun	23	85	5	7	90	76.7	94.4
2.		Karat Daun	26	79	11	4	87.5	86.7	87.8
3.		Bercak Mata	18	99	0	3	97.5	85.7	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	7	111	0	2	98.3	77.8	100

Grafik hasil persentase akurasi, sensitivitas dan spesifisitas dari data uji dengan kernel linear dengan *input* ciri GLCM ditunjukkan pada Gambar 5.25.



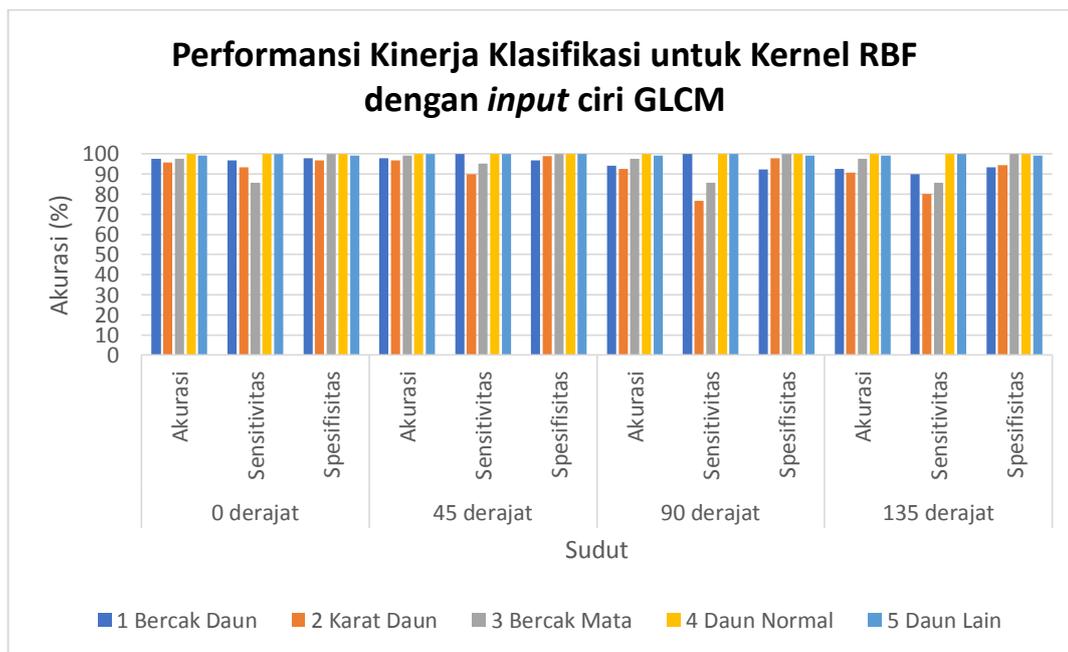
Gambar 5.25 Grafik hasil performansi klasifikasi untuk kernel linear dengan input ciri GLCM

Berdasarkan Tabel 5.34 dan Gambar 5.25 hasil klasifikasi penyakit daun kacang tanah dengan menggunakan *input* ciri GLCM dan diklasifikasikan dengan menggunakan metode M-SVM strategi DAGSVM dengan kernel linear memberikan hasil akurasi, sensitivitas dan spesifisitas tertinggi dengan menggunakan jarak ketetanggaan piksel $d=1$ dan sudut 45° dengan nilai akurasi 95%, sensitivitas 93.3% dan spesifisitas 95.6% untuk kelas bercak daun; nilai akurasi 92.5%, sensitivitas 86.7% dan spesifisitas 94.4% untuk kelas karat daun; nilai akurasi 81.7%, sensitivitas 85.7% dan spesifisitas 98.9% untuk kelas bercak mata; nilai akurasi 100%, sensitivitas 100% dan spesifisitas 100% untuk kelas daun normal; nilai akurasi 99.2%, sensitivitas 88.9% dan spesifisitas 100% untuk kelas daun lain.

Tabel 5.35 menunjukkan hasil persentase akurasi, sensitivitas, spesifisitas dari hasil performansi sistem klasifikasi dengan menggunakan kernel RBF dengan *input* hasil ekstraksi ciri tekstur GLCM dengan sudut 0° , 45° , 90° dan 135° pada penelitian ini.

Tabel 5.35 Performansi kinerja klasifikasi untuk kernel RBF dengan input ciri GLCM

No	Sudut	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	0°	Bercak Daun	29	88	2	1	97.5	96.7	97.8
2.		Karat Daun	28	87	3	2	95.8	93.3	96.7
3.		Bercak Mata	18	99	0	3	97.5	85.7	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	110	1	0	99.2	100	99.1
1.	45°	Bercak Daun	30	87	3	0	97.5	100	96.7
2.		Karat Daun	27	89	1	3	96.7	90	98,9
3.		Bercak Mata	20	99	0	1	99.2	95.2	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100
1.	90°	Bercak Daun	30	83	7	0	94.2	100	92.2
2.		Karat Daun	23	88	2	7	92.5	76.7	97.8
3.		Bercak Mata	18	99	0	3	97.5	85.7	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	110	1	0	99.2	100	99.1
1.	135°	Bercak Daun	27	84	6	3	92.5	90	93.3
2.		Karat Daun	24	85	5	6	90.8	80	94.4
3.		Bercak Mata	18	99	0	3	97.5	85.7	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	110	1	0	99.2	100	99.1



Gambar 5.26 Grafik hasil performansi klasifikasi untuk kernel RBF dengan input ciri GLCM

Berdasarkan Tabel 5.35 dan Gambar 5.26 hasil klasifikasi penyakit daun kacang tanah dengan menggunakan *input* ciri GLCM dan diklasifikasikan dengan menggunakan metode M-SVM strategi DAGSVM dengan kernel RBF memberikan hasil akurasi, sensitivitas dan spesifisitas tertinggi dengan menggunakan jarak ketetanggaan piksel $d=1$ dan sudut 45^0 dengan nilai akurasi 97.8%, sensitivitas 100% dan spesifisitas 96.7% untuk kelas bercak daun; nilai akurasi 96.7%, sensitivitas 90% dan spesifisitas 98.9% untuk kelas karat daun; nilai akurasi 99.2%, sensitivitas 95.2% dan spesifisitas 100% untuk kelas bercak mata; akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun normal; akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun lain.

5.2.1.2 Pengujian performansi klasifikasi penyakit daun kacang tanah dengan M-SVM strategi DAGSVM menggunakan *input* ciri HSV

Pada skenario percobaan kedua dilakukan pengujian terhadap performansi klasifikasi penyakit daun tanaman kacang tanah dengan menggunakan metode M-SVM strategi DAGSVM berdasarkan *input* hasil ekstraksi ciri warna menggunakan ruang warna HSV. Percobaan ini dilakukan untuk mengetahui performansi dari sistem klasifikasi berdasarkan karakteristik perbedaan warna penyakit daun kacang tanah antara satu jenis penyakit dengan jenis penyakit pada daun kacang tanah lainnya. Tabel 5.36 menunjukkan hasil performansi sistem klasifikasi penyakit daun tanaman kacang tanah, yaitu akurasi, sensitivitas dan spesifisitas dengan klasifikasinya menggunakan kernel *polynomial* dengan *input* ciri ekstraksi warna dalam ruang warna HSV dengan ciri yang diekstraksi, yaitu rata-rata dari H, rata-rata dari S dan rata-rata dari V.

Tabel 5.36 Performansi kinerja klasifikasi dengan kernel *polynomial* menggunakan *input* ciri HSV

No	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	Bercak Daun	10	90	0	20	83.3	33.3	100
2.	Karat Daun	27	68	22	3	79.2	90	75.6
3.	Bercak Mata	19	96	3	2	95.8	90.5	96.9
4.	Daun Normal	30	90	0	0	100	100	100
5.	Daun Lain	9	111	0	0	100	100	100

Berikut adalah contoh perhitungan nilai akurasi, sensitivitas dan spesifisitas pada sistem klasifikasi penyakit daun tanaman kacang tanah menggunakan kernel *polynomial* dengan *input* ciri HSV pada kelas bercak daun adalah sebagai berikut :

$$TP = 10$$

$$TN = 90$$

$$FP = 0$$

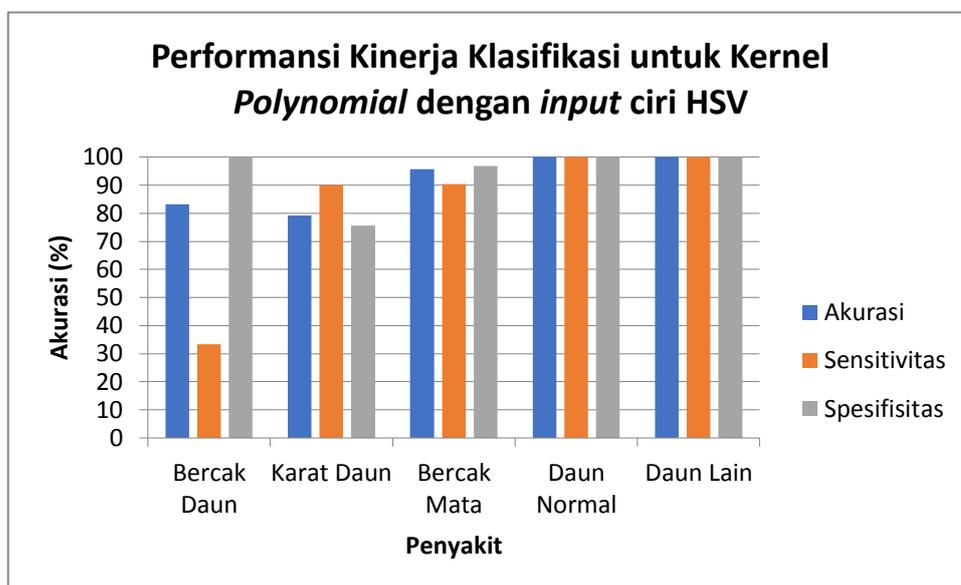
$$FN = 20$$

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN} = \frac{10 + 90}{10 + 90 + 0 + 20} = \frac{100}{120} \times 100\% = 83.3\%$$

$$Sensitivitas = \frac{TP}{TP + FN} = \frac{10}{10 + 20} = \frac{10}{30} \times 100\% = 33.3\%$$

$$Spesifisitas = \frac{TN}{TN + FP} = \frac{90}{90 + 0} = \frac{90}{90} \times 100\% = 100\%$$

Grafik hasil persentase akurasi, sensitivitas dan spesifisitas dari data uji dengan kernel *polynomial* dengan *input* ciri ciri HSV ditunjukkan pada Gambar 5.27.



Gambar 5.27 Grafik hasil persentase performansi klasifikasi dengan menggunakan kernel *polynomial* dengan input ciri HSV

Berdasarkan Tabel 5.36 dan Gambar 5.27 menunjukkan hasil klasifikasi penyakit daun tanaman kacang tanah dengan menggunakan metode M-SVM strategi DAGSVM menggunakan kernel *polynomial* serta dengan menggunakan *input* ciri HSV memberikan hasil, yaitu nilai akurasi 83.3%, sensitivitas 33.3% dan spesifisitas 100% untuk kelas bercak daun; nilai akurasi 79.2%, sensitivitas 90% dan spesifisitas 75.6% untuk kelas karat daun; nilai akurasi 95.8%, sensitivitas 90.5% dan spesifisitas 96.9% untuk kelas bercak

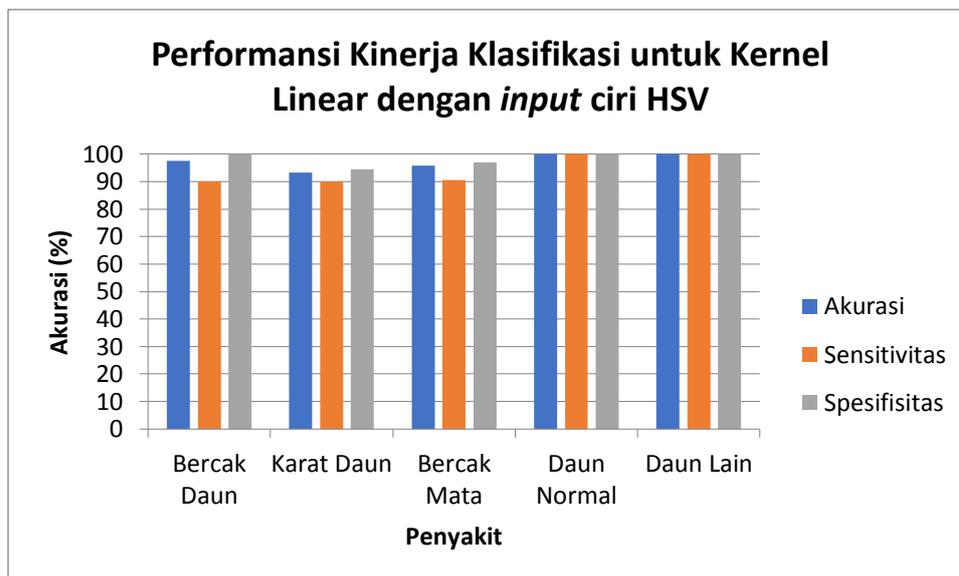
mata; nilai akurasi 100%, sensitivitas 100% dan spesifisitas 100% untuk kelas daun normal; nilai akurasi 100%, sensitivitas 100% dan spesifisitas 100% untuk kelas daun lain.

Tabel 5.37 menunjukkan hasil persentase akurasi, sensitivitas dan spesifisitas dari hasil performansi sistem klasifikasi penyakit daun kacang tanah dengan menggunakan kernel linear dengan *input*, yaitu ciri warna HSV.

Tabel 5.37 Hasil performansi klasifikasi menggunakan kernel linear dengan input ciri HSV

No	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	Bercak Daun	27	90	0	3	97.5	90	100
2.	Karat Daun	27	85	5	3	93.3	90	94.4
3.	Bercak Mata	19	96	3	2	95.8	90.5	96.9
4.	Daun Normal	30	90	0	0	100	100	100
5.	Daun Lain	9	111	0	0	100	100	100

Grafik hasil persentase akurasi, sensitivitas dan spesifisitas dari data uji dengan kernel linear dengan *input* ciri GLCM ditunjukkan pada Gambar 5.28.



Gambar 5.28 Grafik hasil performansi klasifikasi menggunakan kernel linear dengan input ciri HSV

Berdasarkan Tabel 5.37 dan Gambar 5.28 hasil akurasi, sensitivitas dan spesifisitas untuk mengetahui performansi dari sistem klasifikasi penyakit daun tanaman kacang tanah menggunakan metode M-SVM strategi DAGSVM pada kernel linear dan dengan menggunakan *input* ciri HSV, maka didapatkan hasil akurasi 97.5%, sensitivitas 90% dan spesifisitas 100% untuk kelas bercak daun; nilai akurasi 93.3%, sensitivitas 90% dan spesifisitas 94.4% untuk kelas karat daun; nilai akurasi 95.8%, sensitivitas 90.5% dan

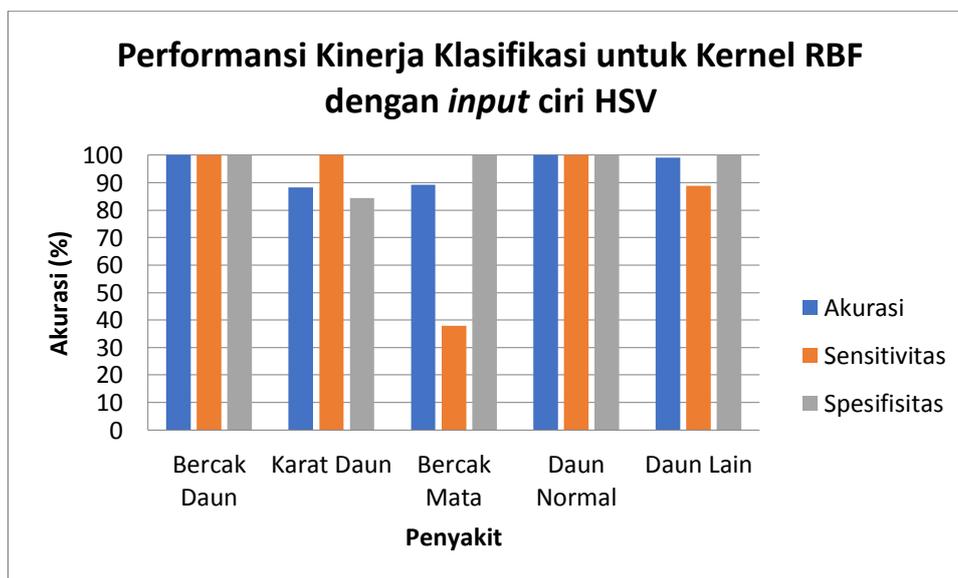
spesifisitas 96.9% untuk kelas bercak mata; akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun normal; akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun lain.

Tabel 5.38 menunjukkan hasil persentase akurasi, sensitivitas dan spesifisitas dari hasil performansi sistem klasifikasi penyakit daun kacang tanah dengan menggunakan kernel RBF dengan *input*, yaitu ciri warna HSV.

Tabel 5.38 Hasil performansi klasifikasi menggunakan kernel RBF dengan input ciri HSV

No	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	Bercak Daun	30	90	0	0	100	100	100
2.	Karat Daun	30	76	14	0	88.3	100	84.4
3.	Bercak Mata	8	99	0	13	89.2	38	100
4.	Daun Normal	30	90	0	0	100	100	100
5.	Daun Lain	8	111	0	1	99.2	88.9	100

Grafik hasil persentase akurasi, sensitivitas dan spesifisitas dari data uji dengan kernel RBF dengan *input* ciri GLCM ditunjukkan pada Gambar 5.29.



Gambar 5.29 Grafik hasil persentase performansi klasifikasi dengan menggunakan kernel RBF dengan input ciri HSV

Berdasarkan Tabel 5.38 dan Gambar 5.29 menunjukkan hasil klasifikasi penyakit daun tanaman kacang tanah dengan menggunakan metode M-SVM strategi DAGSVM menggunakan kernel RBF serta dengan menggunakan *input* ciri HSV memberikan hasil, yaitu nilai akurasi 100%, sensitivitas 100% dan spesifisitas 100% untuk kelas bercak daun; nilai akurasi 88.3%, sensitivitas 100% dan spesifisitas 84.4% untuk kelas karat daun; nilai

akurasi 89.2%, sensitivitas 38% dan spesifisitas 100% untuk kelas bercak mata; nilai akurasi 100%, sensitivitas 100% dan spesifisitas 100% untuk kelas daun normal; nilai akurasi 99.2%, sensitivitas 88.9% dan spesifisitas 100% untuk kelas daun lain.

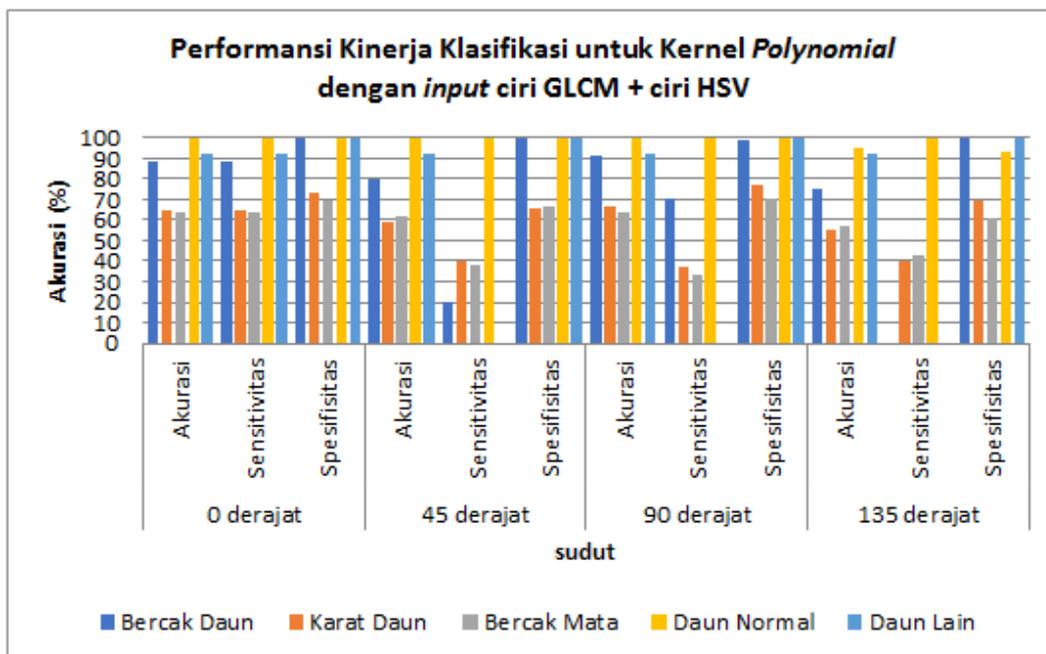
5.2.1.3 Pengujian performansi klasifikasi penyakit daun kacang tanah dengan M-SVM strategi DAGSVM menggunakan *input* ciri GLCM dan ciri HSV

Pada skenario percobaan ketiga digunakan gabungan dari hasil ciri ekstraksi tekstur GLCM serta ciri ekstraksi warna HSV sebagai *input* proses klasifikasi dengan menggunakan metode M-SVM strategi DAGSVM. Skenario percobaan ini dilakukan untuk mengetahui performansi sistem klasifikasi penyakit daun tanaman kacang tanah tidak hanya berdasarkan karakteristik tekstur saja, tetapi juga berdasarkan karakteristik warna dari penyakit daun kacang tanah. Tabel 5.39 adalah hasil persentase akurasi, sensitivitas dan spesifisitas dari hasil performansi sistem klasifikasi dengan menggunakan kernel *polynomial* dengan *input* ciri tekstur GLCM dengan orientasi sudut 0° , 45° , 90° dan 135° dan ciri warna HSV pada penelitian ini.

Tabel 5.39 Performansi kinerja klasifikasi untuk kernel *polynomial* *input* ciri GLCM+HSV

No	Sudut	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	0°	Bercak Daun	16	90	0	14	88.3	53.3	100
2.		Karat Daun	12	66	24	18	65	40	73.3
3.		Bercak Mata	8	69	30	13	64.2	38.1	69.7
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	0	111	0	9	92.5	0	100
1.	45°	Bercak Daun	6	90	0	24	80	20	100
2.		Karat Daun	12	59	31	18	59.2	40	65.5
3.		Bercak Mata	8	66	33	13	61.7	38.1	66.7
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	0	111	0	9	92.5	0	100
1.	90°	Bercak Daun	21	89	1	9	91.7	70	98.9
2.		Karat Daun	11	69	21	19	66.7	36.7	76.7
3.		Bercak Mata	7	70	29	14	64.2	33.3	70.7
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	0	111	0	9	92.5	0	100
1.	135°	Bercak Daun	0	90	0	30	75	0	100
2.		Karat Daun	12	54	24	18	55	40	69.2
3.		Bercak Mata	9	60	39	12	57.5	42.8	60.6
4.		Daun Normal	30	84	6	0	95	100	93.3
5.		Daun Lain	0	111	0	9	92.5	0	100

Grafik hasil persentase akurasi, sensitivitas dan spesifisitas dari data uji dengan kernel *polynomial* dengan *input* ciri GLCM + ciri HSV ditunjukkan pada Gambar 5.30.



Gambar 5.30 Grafik hasil performansi klasifikasi untuk kernel *polynomial* dengan input ciri GLCM + ciri HSV

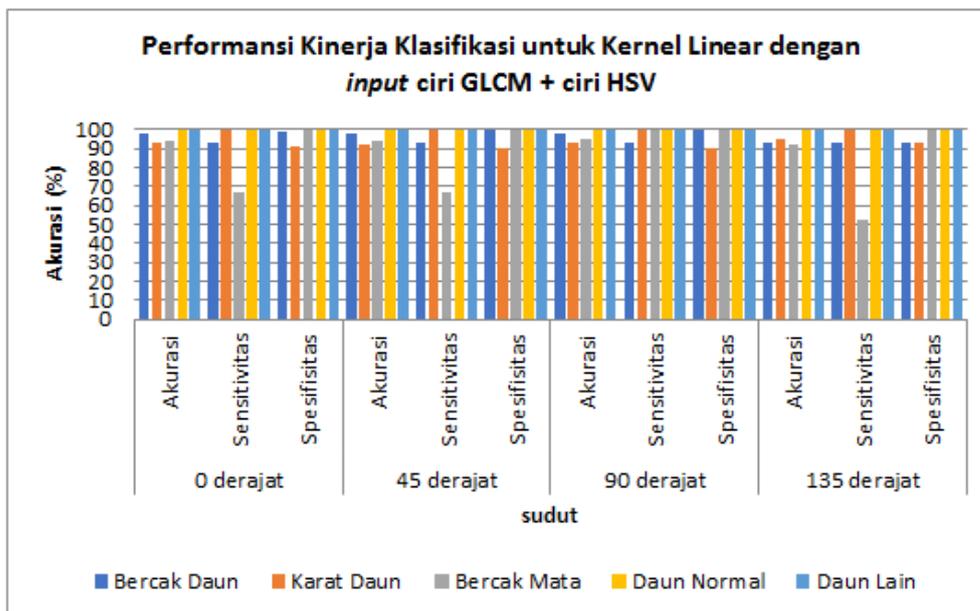
Berdasarkan Tabel 5.39 dan Gambar 5.30 menunjukkan bahwa hasil persentase akurasi, sensitivitas dan spesifisitas untuk data uji dari klasifikasi penyakit daun kacang tanah berdasarkan ciri GLCM dan ciri HSV dan diklasifikasikan menggunakan *Multiclass SVM* strategi DAGSVM dengan kernel *polynomial*, diperoleh hasil terbaik, yaitu dengan menggunakan *input* ciri tekstur GLCM dengan sudut 90° dengan nilai akurasi 91.7%, sensitivitas 70% dan spesifisitas 98.9% untuk kelas bercak daun; nilai akurasi 66.7%, sensitivitas 36.7% dan spesifisitas 76.7% untuk kelas karat daun; nilai akurasi 64.2%, sensitivitas 33.3% dan spesifisitas 70.7% untuk kelas bercak mata; nilai akurasi 100%, sensitivitas 100% dan spesifisitas 100% untuk kelas daun normal; dan nilai akurasi 92.5%, sensitivitas 0% dan spesifisitas 100% untuk kelas daun lain.

Tabel 5.40 menunjukkan hasil persentase akurasi, sensitivitas dan spesifisitas dari hasil performansi sistem klasifikasi penyakit daun kacang tanah dengan menggunakan kernel linear dengan *input*, yaitu kombinasi dari ciri tekstur GLCM dengan sudut 0° , 45° , 90° dan 135° dan ciri warna HSV.

Tabel 5.40 Performansi kinerja klasifikasi untuk kernel linear dengan input ciri GLCM + ciri HSV

No	Sudut	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	0°	Bercak Daun	28	89	1	2	97.5	93.3	98.9
2.		Karat Daun	30	82	8	0	93.3	100	91.1
3.		Bercak Mata	14	99	0	7	94.2	66.7	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100
1.	45°	Bercak Daun	28	90	0	2	98.3	93.3	100
2.		Karat Daun	30	81	9	0	92.5	100	90
3.		Bercak Mata	14	99	0	7	94.2	66.7	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100
1.	90°	Bercak Daun	28	90	0	2	98.3	93.3	100
2.		Karat Daun	30	82	8	0	93.3	100	90
3.		Bercak Mata	15	99	0	6	95	100	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100
1.	135°	Bercak Daun	28	84	6	2	93.3	93.3	93.3
2.		Karat Daun	30	84	6	0	95	100	93.3
3.		Bercak Mata	11	99	0	10	91.7	52.3	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100

Grafik hasil uji performansi akurasi, sensitivitas dan spesifisitas dari data uji pada klasifikasi penyakit daun kacang ditunjukkan pada Gambar 5.31.



Gambar 5.31 Grafik hasil performansi klasifikasi untuk kernel linear dengan input ciri GLCM + ciri HSV

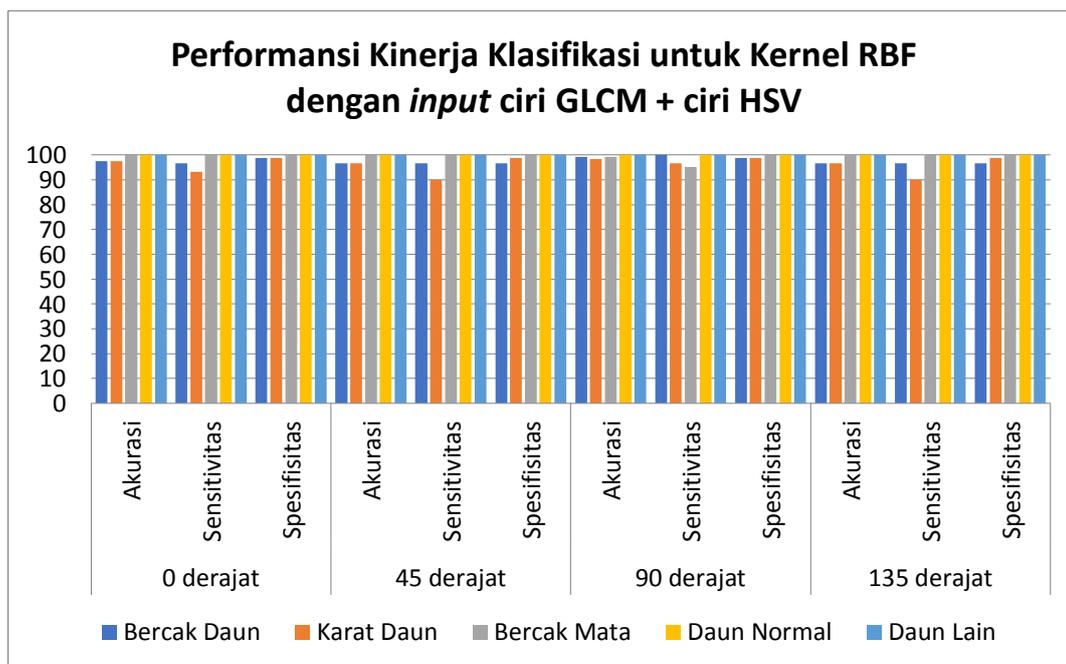
Berdasarkan Tabel 5.40 dan Gambar 5.31 menunjukkan bahwa hasil performansi klasifikasi penyakit daun kacang tanah menggunakan metode *Multiclass SVM* strategi DAGSVM dengan kernel linear pada data uji diperoleh hasil terbaik, yaitu menggunakan *input* ciri tekstur GLCM dengan sudut 90° dengan nilai akurasi 98.3%, sensitivitas 93.3% dan spesifisitas 100% untuk kelas bercak daun; nilai akurasi 93.3%, sensitivitas 100% dan spesifisitas 90% untuk kelas karat daun; nilai akurasi 95%, sensitivitas 100% dan spesifisitas 100% untuk kelas bercak mata; akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun normal; dan akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun lain.

Tabel 5.41 menunjukkan hasil persentase akurasi, sensitivitas dan spesifisitas dari hasil performansi sistem klasifikasi penyakit daun kacang tanah dengan menggunakan kernel RBF dengan *input*, yaitu kombinasi dari ciri tekstur GLCM dengan sudut 0° , 45° , 90° dan 135° dan ciri warna HSV.

Tabel 5.41 Performansi kinerja klasifikasi untuk kernel RBF dengan input ciri GLCM + ciri HSV

No	Sudut	Nama Penyakit	TP	TN	FP	FN	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1.	0°	Bercak Daun	29	88	2	1	97.5	96.7	98.9
2.		Karat Daun	28	89	1	2	97.5	93.3	98.9
3.		Bercak Mata	21	99	0	0	100	100	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100
1.	45°	Bercak Daun	29	87	3	1	96.7	96.7	96.7
2.		Karat Daun	27	89	1	3	96.7	90	98.8
3.		Bercak Mata	21	99	0	0	100	100	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100
1.	90°	Bercak Daun	30	89	1	0	99.2	100	98.9
2.		Karat Daun	29	89	1	1	98.3	96.7	98.9
3.		Bercak Mata	20	99	0	1	99.2	95.2	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100
1.	135°	Bercak Daun	29	87	3	1	96.7	96.7	96.7
2.		Karat Daun	27	89	1	3	96.7	90	98.9
3.		Bercak Mata	21	99	0	0	100	100	100
4.		Daun Normal	30	90	0	0	100	100	100
5.		Daun Lain	9	111	0	0	100	100	100

Grafik hasil uji performansi akurasi, sensitivitas dan spesifisitas dari data uji pada klasifikasi penyakit daun kacang diperlihatkan dengan Gambar 5.32.



Gambar 5.32 Grafik hasil performansi klasifikasi untuk kernel RBF dengan input ciri GLCM + ciri HSV

Berdasarkan Tabel 5.41 dan Gambar 5.32 menunjukkan bahwa hasil performansi klasifikasi penyakit daun kacang tanah menggunakan metode *Multiclass* SVM strategi DAGSVM dengan kernel RBF pada data uji diperoleh hasil terbaik, yaitu menggunakan *input* ciri tekstur GLCM dengan sudut 90° dengan nilai akurasi 99.2%, sensitivitas 100% dan spesifisitas 98.9% untuk kelas bercak daun; nilai akurasi 98.3%, sensitivitas 96.7% dan spesifisitas 98.9% untuk kelas karat daun; nilai akurasi 95.2%, sensitivitas 100% dan spesifisitas 100% untuk kelas bercak mata; akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun normal; dan akurasi nilai 100%, sensitivitas nilai 100% dan spesifisitas nilai 100% untuk kelas daun lain.

5.2.2 Pengujian *Confusion matrix*

Confusion matrix merupakan sebuah tabel untuk memperlihatkan dan membandingkan antara nilai kelas sebenarnya dengan nilai kelas hasil dari prediksi. Analisis *confusion matrix* pada penelitian ini digunakan untuk mengetahui kinerja sistem klasifikasi *Multiclass* SVM dengan strategi DAGSVM dalam mengklasifikasikan penyakit daun kacang tanah dengan tepat antara nilai prediksi dengan nilai aktualnya sesuai dengan kelas penyakit daun kacang tanah.

5.2.2.1 *Confusion matrix* hasil klasifikasi M-SVM dengan strategi DAGSVM dengan input ciri GLCM

Hasil *confusion matrix* untuk klasifikasi *Multiclass SVM* dengan strategi DAGSVM dengan menggunakan kernel *polynomial* untuk data uji dengan input ciri tekstur GLCM ditampilkan dengan Tabel 5.42.

Tabel 5.42 *Confusion matrix* klasifikasi dengan kernel *polynomial* dengan input ciri GLCM

0°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	63.3%	3.3%	33.4%	0%	0%
Karat Daun	33.35	0%	66.7%	0%	0%
Bercak Mata	0%	38.1%	61.9%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	66.7%	33.3%	0%	0%
45°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	63.4%	3.3%	33.3%	0%	0%
Karat Daun	33.3%	0%	66.7%	0%	0%
Bercak Mata	0%	66.7%	33.3	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	66.7%	22.2%	0%	11.1%
90°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	60%	6.7%	33.3%	0%	0%
Karat Daun	20%	3.3%	76.7%	0%	0%
Bercak Mata	0%	52.4%	47.6%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	66.7%	22.2%	0%	0%
135°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	66.7%	0%	33.3%	0%	0%
Karat Daun	36.7%	0%	63.3%	0%	0%
Bercak Mata	4.77%	28.6%	52.4%	14.3%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	55.6%	44.4%	0%	0%

Hasil *confusion matrix* pada Tabel 5.42 menunjukkan bahwa dengan menggunakan *input* ciri tekstur GLCM dengan sudut 90° dan jarak ketetanggaan piksel $d=1$ serta diklasifikasikan menggunakan metode M-SVM strategi DAGSVM, sistem mampu mengklasifikasikan 60% dari 30 data sebagai kelas bercak daun, 3.3% dari 30 data sebagai kelas karat daun, 47.6% dari 21 data sebagai kelas bercak mata, 100% dari 30 data sebagai kelas daun normal dan 0% dari 9 data sebagai kelas daun lain.

Sedangkan untuk *confusion matrix* dari hasil klasifikasi penyakit daun tanaman kacang tanah menggunakan kernel linear pada klasifikasi M-SVM strategi DAGSVM dengan *input* ciri tekstur GLCM untuk data uji ditampilkan dengan Tabel 5.43.

Tabel 5.43 *Confusion matrix* klasifikasi dengan kernel linear dengan *input* ciri GLCM

0°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	86.7%	13.3%	0%	0%	0%
Karat Daun	6.7%	80%	6.7%	0%	6.6%
Bercak Mata	4.8%	0%	95.2%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	33.3%	0%	66.7%
45°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	93.3%	6.7%	0%	0%	0%
Karat Daun	13.3%	86.7%	0%	0%	0%
Bercak Mata	0%	14.3%	85.7%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	11.1%	0%	88.9%
90°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	86.7%	13.3%	0%	0%	0%
Karat Daun	0%	90%	0%	0%	10%
Bercak Mata	0%	33.3%	66.7%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	11.1%	0%	0%	88.9%
135°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	76.7%	23.3%	0%	0%	0%
Karat Daun	13.3%	86.7%	0%	0%	0%
Bercak Mata	4.8%	9.5%	85.7%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	22.2%	0%	0%	77.8%

Hasil *confusion matrix* pada Tabel 5.43 menunjukkan bahwa sistem klasifikasi dengan menggunakan *input* ciri tekstur GLCM dengan sudut 45° dan jarak ketetanggaan piksel $d=1$ mampu mengklasifikasikan 93.3% dari 30 data sebagai kelas bercak daun, 86.7% dari 30 data sebagai kelas karat daun, 85.7% dari 21 data sebagai kelas bercak mata, 100% dari 30 data sebagai kelas daun normal dan 88.9% sebagai kelas daun lain. Hasil *confusion matrix* ini didapatkan pada sistem klasifikasi dengan M-SVM strategi DAGSVM dengan menggunakan kernel linear.

Hasil *confusion matrix* untuk klasifikasi *Multiclass* SVM dengan strategi DAGSVM dengan menggunakan kernel RBF untuk data uji dengan *input* ciri tekstur GLCM diperlihatkan dengan Tabel 5.44.

Tabel 5.44 *Confusion matrix* klasifikasi dengan kernel RBF dengan input ciri GLCM

0°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	96.7%	3.3%	0%	0%	0%
Karat Daun	6.7%	93.3%	0%	0%	0%
Bercak Mata	0%	9.6%	85.7%	0%	4.7%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
45°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	100%	0%	0%	0%	0%
Karat Daun	10%	90%	0%	0%	0%
Bercak Mata	0%	4.8%	95.2%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
90°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	100%	0%	0%	0%	0%
Karat Daun	23,3%	76.7	0%	0%	0%
Bercak Mata	0%	9.5%	85.7%	0%	4.8%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
135°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	90%	10%	0%	0%	0%
Karat Daun	20%	80%	0%	0%	0%
Bercak Mata	0%	9.5%	85.7%	0%	4.8%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%

Hasil *confusion matrix* pada Tabel 5.44 menunjukkan bahwa dengan menggunakan *input* ciri tekstur GLCM dengan sudut 45^0 dan jarak ketetanggaan piksel $d=1$ serta diklasifikasikan menggunakan metode M-SVM strategi DAGSVM dengan menggunakan kernel RBF, sistem mampu mengklasifikasikan 100% dari 30 data sebagai kelas bercak daun, 90% dari 30 data sebagai kelas karat daun, 95.2% dari 21 data sebagai kelas bercak mata, 100% dai 30 data sebagai kelas daun normal dan 100% dari 9 data sebagai kelas daun lain.

5.2.2.2 *Confusion matrix* hasil klasifikasi M-SVM dengan strategi DAGSVM berdasarkan *input* ciri HSV

Hasil *confusion matrix* dari proses klasifikasi penyakit daun tanaman kacang tanah dengan menggunakan *input* ciri HSV dan diklasifikasikan dengan menggunakan kernel *polynomial* ditampilkan dengan Tabel 5.45.

Tabel 5.45 *Confusion matrix* hasil klasifikasi menggunakan kernel *polynomial* dengan *input* ciri HSV

	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	33.3%	66.7%	0%	0%	0%
Karat Daun	0%	90%	10%	0%	0%
Bercak Mata	0%	9.5%	90.5%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%

Hasil *confusion matrix* pada Tabel 5.45 menunjukkan hasil klasifikasi dengan menggunakan metode klasifikasi M-SVM dengan strategi DAGSVM menggunakan *input* ciri HSV, sistem mampu mengklasifikasikan dengan tepat 33.3% dari 30 data sebagai kelas bercak daun, 90% dari 30 data sebagai kelas karat daun, 90.5% dari 21 data sebagai kelas bercak mata, 100% dari 30 data sebagai kelas daun normal dan 100% dari 9 data sebagai kelas daun lain.

Sedangkan hasil *confusion matrix* pada sistem klasifikasi penyakit daun tanaman kacang tanah menggunakan kernel linear dengan *input* ciri HSV diperlihatkan dengan Tabel 5.46.

Tabel 5.46 *Confusion matrix* klasifikasi menggunakan kernel linear dengan input ciri HSV

	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	90%	10%	0%	0%	0%
Karat Daun	0%	90%	10%	0%	0%
Bercak Mata	0%	9.5%	90.5%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%

Hasil *confusion matrix* pada Tabel 5.46 menunjukkan bahwa sistem klasifikasi dengan menggunakan *input* ciri HSV dan diklasifikasikan dengan menggunakan metode M-SVM strategi DAGSVM sistem mampu mengklasifikasikan penyakit daun tanaman kacang tanah dengan tepat, yaitu 90% dari 30 data sebagai kelas bercak daun, 90% dari 30 data sebagai kelas karat daun, 90.5% dari 21 data sebagai kelas bercak mata, 100% dari 30 data sebagai kelas daun normal dan 100% dari 9 data sebagai kelas daun lain.

Hasil *confusion matrix* dari proses klasifikasi penyakit daun tanaman kacang tanah dengan menggunakan *input* ciri HSV dan diklasifikasikan dengan menggunakan kernel RBF diperlihatkan dengan Tabel 5.47.

Tabel 5.47 *Confusion matrix* klasifikasi menggunakan kernel RBF dengan input ciri HSV

	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	100%	0%	0%	0%	0%
Karat Daun	0%	100%	0%	0%	0%
Bercak Mata	0%	61.9%	38.1%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	11.1%	0%	0%	88.9%

Hasil *confusion matrix* pada Tabel 5.47 menunjukkan bahwa sistem klasifikasi dengan menggunakan *input* ciri HSV dan diklasifikasikan dengan menggunakan metode M-SVM strategi DAGSVM sistem mampu mengklasifikasikan penyakit daun tanaman kacang tanah dengan tepat, yaitu 100% dari 30 data sebagai kelas bercak daun, 100% dari 30 data sebagai kelas karat daun, 38.1% dari 21 data sebagai kelas bercak mata, 100% dari 30 data sebagai kelas daun normal dan 88.9% dari 9 data sebagai kelas daun lain.

5.2.2.3 Confusion matrix hasil klasifikasi M-SVM dengan strategi DAGSVM berdasarkan input ciri GLCM dan ciri HSV

Hasil *confusion matrix* untuk membandingkan hasil aktual dengan hasil prediksi pada sistem klasifikasi *Multiclass SVM* dengan strategi DAGSVM dengan menggunakan kernel *polynomial* untuk data uji dengan input ciri tekstur GLCM + ciri HSV ditampilkan dengan Tabel 5.48.

Tabel 5.48 *Confusion matrix* klasifikasi menggunakan kernel *polynomial* dengan input ciri GLCM + ciri HSV

0°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	53.4%	13.3%	33.3%	0%	0%
Karat Daun	0%	40%	60%	0%	0%
Bercak Mata	0%	62%	38%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	77,8%	22.2%	0%	0%
45°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	20%	43.3%	36.7%	0%	0%
Karat Daun	0%	40%	60%	0%	0%
Bercak Mata	0%	61.9%	38.1%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	55.5%	44.5%	0%	0%
90°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	70%	3.3%	26.7%	0%	0%
Karat Daun	3.3%	36.7%	60%	0%	0%
Bercak Mata	0%	66.7%	33.3%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	66.7%	33.3%	0%	0%
135°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	0%	53.3%	46.75	0%	0%
Karat Daun	0%	40%	60%	0%	0%
Bercak Mata	0%	28.6%	42.8%	28.6%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	22.2%	77.8%	0%	0%

Confusion matrix pada Tabel 5.48 menunjukkan bahwa dengan menggunakan ciri tekstur GLCM dengan orientasi sudut 90° dan ciri warna HSV sistem klasifikasi mampu mengklasifikasikan penyakit daun kacang tanah dengan tepat sebesar 70% dari 30 citra untuk kelas bercak daun, 36.7% dari 30 citra untuk kelas karat daun, 33.3% dari 21 citra untuk kelas bercak mata, 100% dari 30 citra untuk kelas daun normal dan 0% dari 9 citra untuk kelas daun lain.

Tabel 5.49 menunjukkan tabel *confusion matrix* dengan data uji untuk klasifikasi penyakit daun kacang tanah menggunakan metode *Multiclass SVM* dengan strategi DAGSVM menggunakan linear kernel.

Tabel 5.49 *Confusion matrix* klasifikasi menggunakan kernel linear berdasarkan input ciri GLCM + ciri HSV

0°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	93.3%	6.7%	0%	0%	0%
Karat Daun	0%	100%	0%	0%	0%
Bercak Mata	4.7%	28.6%	66.7%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
45°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	93.3%	6.7%	0%	0%	0%
Karat Daun	0%	100%	0%	0%	0%
Bercak Mata	0%	33.3%	66.7%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
90°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	93.35	6.7%	0%	0%	0%
Karat Daun	0%	100%	0%	0%	0%
Bercak Mata	0%	28.6%	71.4%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
135°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	93.3%	6.7%	0%	0%	0%
Karat Daun	0%	100%	0%	0%	0%
Bercak Mata	28.6%	19%	52.4%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%

Tabel 5.49 menunjukkan hasil *confusion matrix* dari klasifikasi penyakit daun kacang tanah menggunakan metode *Multiclass SVM* strategi DAGSVM dengan menggunakan kernel linear untuk beberapa orientasi sudut ciri tekstur GLCM, yaitu 0° , 45° , 90° dan 135° . Sebagai contoh dengan menggunakan ciri tekstur GLCM dengan orientasi sudut 90° sistem klasifikasi mampu mengklasifikasikan penyakit daun kacang dengan tepat, yaitu 93.5% sebagai kelas bercak daun dari 30 citra, 100% sebagai kelas karat daun dari 30 citra, 71.4% sebagai kelas bercak mata dari 21 citra, 100% sebagai kelas daun normal dari 30 citra dan 100% sebagai kelas daun lain dari 9 citra.

Tabel 5.50 menunjukkan tabel *confusion matrix* dengan data uji untuk klasifikasi penyakit daun kacang tanah menggunakan metode *Multiclass SVM* dengan strategi DAGSVM menggunakan linear kernel.

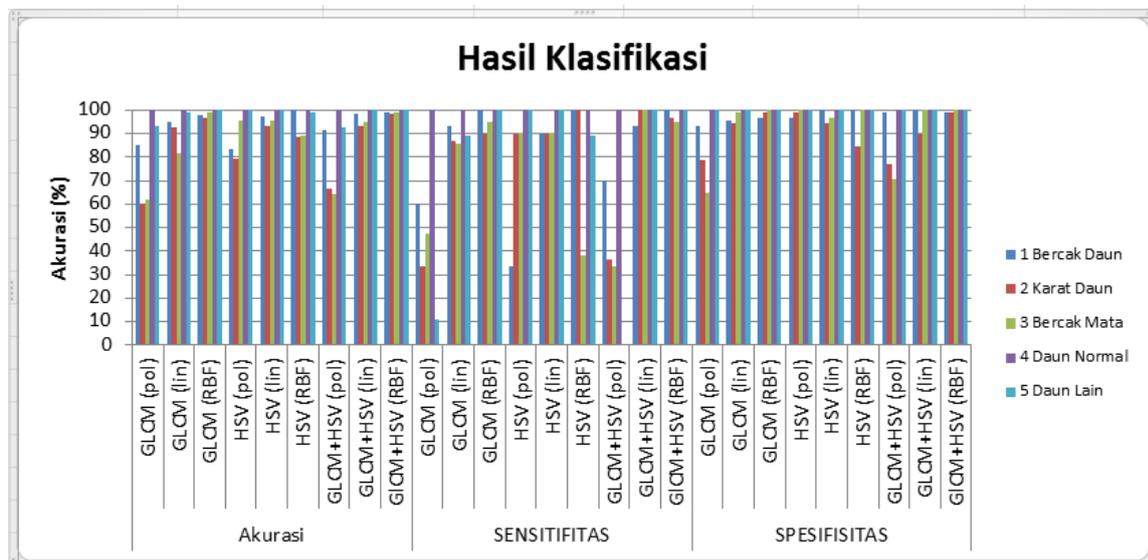
Tabel 5.50 *Confusion matrix* klasifikasi menggunakan kernel RBF berdasarkan input ciri GLCM + ciri HSV

0°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	96.7%	3.3%	0%	0%	0%
Karat Daun	6.7%	93.3%	0%	0%	0%
Bercak Mata	0%	0%	100%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
45°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	96.7%	3.3%	0%	0%	0%
Karat Daun	10%	90	0%	0%	0%
Bercak Mata	0%	0%	100%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
90°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	100%	0%	0%	0%	0%
Karat Daun	3.3%	96.7%	0%	0%	0%
Bercak Mata	0%	4.7%	95.3%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%
135°	Bercak Daun	Karat Daun	Bercak Mata	Daun Normal	Daun Lain
Bercak Daun	96.7%	3.3%	0%	0%	0%
Karat Daun	10%	90%	0%	0%	0%
Bercak Mata	0%	0%	100%	0%	0%
Daun Normal	0%	0%	0%	100%	0%
Daun Lain	0%	0%	0%	0%	100%

Tabel 5.50 menunjukkan hasil *confusion matrix* dari klasifikasi penyakit daun kacang tanah menggunakan metode *Multiclass SVM* strategi DAGSVM dengan menggunakan kernel RBF untuk beberapa orientasi sudut ciri tekstur GLCM, yaitu 0° , 45° , 90° dan 135° . Sebagai contoh dengan menggunakan ciri tekstur GLCM dengan orientasi sudut 90° sistem klasifikasi mampu mengklasifikasikan penyakit daun kacang dengan tepat, yaitu 100% sebagai kelas bercak daun dari 30 citra, 96.7% sebagai kelas karat daun dari 30 citra, 95.3% sebagai kelas bercak mata dari 21 citra, 100% sebagai kelas daun normal dari 30 citra dan 100% sebagai kelas daun lain dari 9 citra.

5.2.3 Analisis hasil skenario dari uji percobaan

Hasil yang sudah didapatkan dari beberapa skenario uji coba, telah membuktikan jika metode yang diajukan memberikan hasil akurat untuk digunakan dalam mengklasifikasikan penyakit daun tanaman kacang tanah. Gambar 5.33 menunjukkan hasil dari sistem klasifikasi penyakit daun tanaman kacang tanah dari setiap hasil uji coba. Hasil yang ditampilkan merupakan hasil akurasi, sensitivitas dan spesifisitas tertinggi dari setiap skenario uji coba.



Gambar 5.33 Hasil klasifikasi penyakit daun kacang tanah

Berdasarkan hasil klasifikasi sistem daun tanaman kacang tanah dengan beberapa skenario uji coba pada Gambar 5.33 menunjukkan bahwa hasil skenario uji coba dengan menggunakan *input* ciri tekstur GLCM pada sistem klasifikasi memberikan hasil yang baik. Ciri GLCM yang diekstraksi, yaitu *angular second moment*, *contrast*, *inverse difference moment*, *entropy*, *correlation*, *variance*, *difference entropy*, *sum average*, *sum entropy*, *diffrence variance*, *sum variance* mampu mengenali karakteristik tekstur penyakit daun tanaman kacang tanah dengan baik. Pada skenario uji coba klasifikasi dengan

menggunakan *input* ciri HSV juga menunjukkan hasil yang bagus. Hal ini menunjukkan bahwa ruang warna HSV bisa digunakan untuk mengenali karakteristik penyakit pada daun tanaman kacang tanah dengan baik. Ciri yang diekstraksi yaitu *mean* dari H, *mean* dari S dan *mean* dari V. Kemudian ketika karakteristik penyakit daun tanaman kacang tanah dikenali cirinya berdasarkan ciri tekstur GLCM dan ciri berdasarkan warna HSV mengindikasikan hasil akurasi lebih bagus daripada jika menggunakan nilai ciri GLCM saja ataupun ciri HSV saja sebagai *input* klasifikasi. Dengan melihat Gambar 5.33 skenario uji coba dengan menggunakan *input* ciri GLCM + ciri HSV pada sistem klasifikasi memberikan hasil akurasi tertinggi mencapai 99.2% untuk kelas bercak daun, 98.3% untuk kelas karat daun, 99.2% untuk kelas bercak mata, 100% untuk kelas daun normal, 100% untuk kelas daun lain. Sehingga pada sistem klasifikasi penyakit daun tanaman kacang tanah pada penelitian ini bahwa hasil nilai akurasi, nilai sensitivitas dan nilai spesifisitas tertinggi didapatkan pada skenario uji coba, yaitu menggunakan ekstraksi ciri tekstur GLCM dengan sudut 90° dengan jarak $d=1$ dan ekstraksi ciri warna HSV sebagai *input* klasifikasi M-SVM strategi DAGSVM dengan menggunakan kernel RBF.

Selain itu, dilakukan pula uji waktu komputasi yang diperlukan untuk klasifikasi penyakit daun tanaman kacang tanah. Pengujian waktu komputasi ini dilakukan terhadap seluruh dataset latih maupun dataset uji. Total seluruh dataset adalah 402 citra dengan pembagian 282 sebagai dataset latih dan 120 sebagai dataet uji. Waktu komputasi yang ditampilkan adalah waktu komputasi yang dibutuhkan dalam setiap tahapan dalam sistem, yaitu waktu komputasi saat proses ekstraksi ciri dan proses waktu klasifikasi ditampilkan dengan Tabel 5.51.

Tabel 5.51 Waktu komputasi

Waktu komputasi sistem (ms)		
Waktu komputasi sistem (Ekstraksi ciri dan klasifikasi)	GLCM+Klasifikasi (kernel linear)	11176.404
	GLCM+Klasifikasi (kernel <i>polynomial</i>)	11382.127
	GLCM+Klasifikasi (kernel RBF)	11698.469
	HSV+Klasifikasi (kernel linear)	21135.377
	HSV + Klasifikasi (kernel <i>polynomial</i>)	21229.43

	HSV + Klasifikasi (kernel RBF)	21388.36
	GLCM+HSV+Klasifikasi (kernel linear)	28065.688
	GLCM+HSV+Klasifikasi (kernel <i>polynomial</i>)	28380.658
	GLCM+HSV+Klasifikasi (kernel RBF)	28523.946

Dengan rincian waktu komputasi sebagai berikut :

Waktu komputasi Ekstraksi Ciri (ms)		
Total waktu Ekstraksi ciri keseluruhan data	GLCM	6534.664
	HSV	16704.84
	GLCM+HSV	22507.691
Waktu Klasifikasi (ms)		
Total waktu klasifikasi keseluruhan data	GLCM (kernel linear)	4641.74
	GLCM (kernel <i>polynomial</i>)	4847.463
	GLCM (RBF)	5163.805
	HSV (kernel linear)	4430.537
	HSV (kernel <i>polynomial</i>)	4524.59
	HSV (RBF)	4683.52
	GLCM+HSV (kernel linear)	5557.997
	GLCM+HSV (kernel <i>polynomial</i>)	5872.967
	GLCM+HSV (kernel RBF)	6016.255

Tabel 5.51 menunjukkan waktu komputasi yang dibutuhkan oleh sistem untuk mengklasifikasikan penyakit daun tanaman kacang tanah. Dengan rincian, yaitu waktu komputasi untuk proses pengambilan ciri serta waktu lama komputasi yang diperlukan dalam proses klasifikasi. Waktu komputasi untuk ekstraksi (pengambilan) ciri merupakan waktu lama komputasi untuk ciri ekstraksi tekstur dan ekstraksi ciri warna. Waktu komputasi untuk ciri ekstraksi tektur, yaitu dari proses merubah citra ke dalam *grayscale*, pembentukan matriks kookurensi sampai normalisasi matriks, perhitungan ekstraksi ciri sampai didapatkan nilai dari hasil perhitungan statistik GLCM. Waktu komputasi untuk

ekstraksi ciri warna, yaitu dari merubah citra ke dalam ruang warna HSV sampai didapatkan hasil dari perhitungan ekstraksi ciri warna. Sedangkan waktu komputasi untuk proses klasifikasi, yaitu dari *load* dataset yang terdiri dari ciri hasil ekstraksi, dilanjutkan dengan proses pelatihan, kemudian proses pengujian, hingga seluruh proses DAGSVM selesai. Waktu komputasi yang diperlihatkan oleh Tabel 5.51 proses ekstraksi ciri GLCM mempunyai waktu proses komputasi lebih cepat daripada dengan proses ekstraksi ciri HSV. Hal ini dikarenakan dalam proses ekstraksi ciri GLCM menggunakan citra *grayscale* (2 dimensi) dan kompleksitasnya algoritma yang lebih rendah. Sedangkan waktu komputasi untuk proses ekstraksi ciri GLCM+ciri HSV memberikan waktu komputasi yang lebih lama, karena sistem harus melakukan proses untuk mendapatkan ciri GLCM dan ciri warna HSV. Waktu komputasi dalam proses klasifikasi dengan input ciri HSV memberikan waktu komputasi lebih cepat, daripada menggunakan input ciri GLCM dikarenakan ciri yang digunakan lebih sedikit daripada GLCM, karena ciri HSV hanya menggunakan 3 ciri sedangkan ciri GLCM menggunakan 11 ciri. Sedangkan menggunakan input ciri GLCM+HSV memberikan waktu komputasi klasifikasi lebih lama, karena menggunakan 11 ciri GLCM + 3 ciri HSV. Waktu klasifikasi menggunakan kernel linear, polynomial dan RBF memberikan perbedaan hasil waktu komputasi yang sedikit (tidak significant). Penggunaan kernel linear dan kernel *polynomial* menghasilkan waktu komputasi yang lebih cepat bila dibandingkan dengan kernel RBF, dikarenakan pada kernel RBF tidak menggunakan parameter tertentu, seperti *desired kernel*. Selain itu kompleksitas algoritma kernel linear dan polynomial lebih sederhana bila dibandingkan dengan kernel RBF. Metode klasifikasi *multiclass* SVM strategi DAGSVM baik digunakan dalam proses klasifikasi citra penyakit daun kacang tanah, karena memiliki waktu komputasi yang cepat pada proses pelatihan dan pengujian.

BAB VI KESIMPULAN

Pada bab VI terdiri dari kesimpulan yang didapatkan dari hasil penelitian ini serta terdiri dari saran untuk mengembangkan penelitian ini.

6.1 Kesimpulan

Sistem klasifikasi penyakit daun kacang tanah telah berhasil didesain pada penelitian ini. Hasil penelitian tentang sistem klasifikasi penyakit daun kacang tanah dapat disimpulkan sebagai berikut :

1. Metode GLCM dan HSV dapat digunakan untuk mengenali karakteristik dari citra penyakit daun tanaman kacang tanah berdasarkan tekstur dan warna dengan baik. Penerapan dari metode GLCM sebagai ekstraksi tekstur, yaitu dengan sudut, 0° , 45° , 90° dan 135° dan dengan menggunakan jarak $d=1$. Ciri tekstur GLCM yang diekstraksi, yaitu *ASM*, *contrast*, *IDM*, *entropy*, *correlation*, *variance*, *difference entropy*, *sum average*, *sum entropy*, *diffrence variance*, *sum variance*. Sedangkan penerapan ekstraksi ciri warna HSV, yaitu dengan mengekstraksi ciri *mean* dari H, *mean* dari S dan *mean* dari V.
2. Berdasarkan hasil percobaan, performansi sistem klasifikasi penyakit daun kacang tanah dengan hasil akurasi, sensitivitas dan spesifisitas tertinggi, yaitu dengan menggunakan *input* ciri tekstur GLCM pada jarak (*distance*) $d=1$ dan dengan sudut GLCM 90° + ciri warna HSV serta diklasifikasikan dengan menggunakan metode *Multiclass SVM* strategi DAGSVM dengan kernel RBF dengan nilai akurasi tertinggi mencapai 99.2%, sensitivitas 100% dan spesifisitas 98.9% untuk kelas bercak daun.
3. Berdasarkan hasil akurasi yang telah didapatkan, bahwa model klasifikasi *Multiclass SVM* dengan pendekatan DAGSVM menggunakan kernel RBF memberikan nilai akurasi lebih bagus jika dibandingkan penggunaan kernel linear dan kernel *polynomial*.

6.2 Saran

Saran dalam pengembangan penelitian ini adalah :

1. Dalam hal penggunaan dataset, bisa menggunakan komposisi jumlah data yang seimbang untuk tiap kelasnya.
2. Sistem ekstraksi tekstur dalam penelitian ini dapat dikembangkan dengan metode lain, seperti Gabor dan LBP.

3. Penelitian dapat dikembangkan dengan menggunakan sistem ekstraksi ciri warna dalam ruang warna lain, yaitu RGB, LAB, YcbCr.
4. Dapat digunakan metode *Multiclass SVM* lain, seperti *one against all (OAA)*, *one against one (OAO)*, *error correcting output coding (ECOC)*, dll.
5. Sistem klasifikasi yang dapat diterapkan dalam penelitian ini seperti KNN, ANN, CNN, *Random Forest*.

DAFTAR PUSTAKA

- Badan Pusat Statistik dan Kementerian Pertanian. (2018). *Statistik Pertanian Agricultural Statistics 2018*. Jakarta: Pusat Data dan Sistem Informasi Pertanian Kementerian Pertanian Republik Indonesia.
- Cholissodin, I., Kurniawati, M., Indriati., and Arwani, I. (2014). Classification of Campus E-Complaint Documents using Directed Acyclic Graph Multi-Class SVM Based on Analytic Hierarchy Process. *International Confernce on Advanced Computer Science and Information System (ICACSI)*. IEEE.
- Din, M.Z., Adnan, S.M., Ahmad, W., Aziz, S., Rashid, J., Ismail, W & Iqbal, M.J. (2018). Identification of Disease in Tomato Plants' Leaf using Image Segmentation and SVM. *ResearchGate Technical Journal, University of Engineering and Technology (UET) Taxila, Paskitan*. 23(2):81-88.
- Dinas Perindustrian dan Perdagangan Jawa Timur. (2021). *Sistem Informasi Ketersediaan dan Perkembangan Harga Bahan Pokok di Jawa Timur*. SISKAPERBAPO.
- Hardaningsih, S. & Sumartini. (2015). *Penyakit-penyakit Penting yang Disebabkan oleh Jamur pada Kacang Tanah dan Cara Pengendaliannya*. Malang: Monograf Balitkabi Malang.
- Kadir, A. & Susanto, A. (2013). *Teori dan Aplikasi Pengolahan Citra*. Yogyakarta: Penerbit Andi Yogyakarta.
- Kulinavar, P. & Hadimani, V.I. (2017). Classification of Leaf Disease Based on Multiclass SVM Classifier. *International Journal of Advance Research. Ideas and Innovations in Technology*. 3(4):321-327.
- Listia, R. & Harjoko, A. (2014). Klasifikasi Massa Pada Citra Mammogram berdasarkan Gray Level Co-occurrence Matrix (GLCM). *Indonesian Journal of Computing and Cybernetics System (IJCCS)*. 8(1):59-68.
- Permata, E., Purnama, I.K.E. and Purnomo, M.H. (2013). Klasifikasi Jenis dan Fase Parasit Malaria Plasmodium Falciparum dan Plasmodium Vivax dalam Sel Darah Merah menggunakan Support Vector Machine One-Against-One. SEMNASTEKNOMEDIA ONLINE.
- Rahayu, M. & Sumartini. (2017). Status Penyakit Utama Tanaman Kacang Tanah dan Kacang Hijau di Lahan Sub Optimal Jawa Timur. Malang: Monograf Balitkabi Malang.

- Ramadhani., Arnia., and Muharar, R. (2020). Klasifikasi Motif Tekstil menggunakan Support Vector Machine Multi Kelas. *JTIK. Universitas Brawijaya*. Vol.7, no.1, February 2020. p.9-108
- Prasetyo, E. (2014). *DATA MINING – Mengolah Data Menjadi Informasi Menggunakan MATLAB*. Yogyakarta: Penerbit Andi Yogyakarta.
- Prastyaningsih., Yunita., and Faticah, C. (2016). Kombinasi Fitur Multiscale Gray Level Co-Occurrence Matrices dan Warna untuk Sistem Temu Kembali Citra Gerabah di Museum Majapahit Trowulan. *Thesis*. Surabaya: Institut Teknologi Surabaya. Thesis.
- Ratnasari, E.K., Mentari, M., Dewi, R.K. & Ginardi, R.V.H. (2014). Sugarcane Leaf Disease Detection and Severity Estimation Based on Segmented Spots Image. *International Conference on Information, Communication Technology and System*. IEEE:93-98.
- Saini, I., Singh, D. & Khosla, A. (2014). Electrocardiogram Beat Classification using Empirical Mode Decomposition and Multiclass Directed Acyclic Graph Support Vector Machine. *Sciendirect Elsevier*. 40(5):1774-1787.
- Siqueira, F.R.d., Schwartz, W.R. & Pedrini, H. (2013). Multiscale Gray Level Co-occurrence Matrices for Texture Description. *Neurocomputing*, Volume 120, pp.336-345.
- Trustinah. (2015). *Morfologi dan Pertumbuhan Kacang Tanah*. Malang: Monograf Balitkabi Malang.

