

**IDENTIFIKASI CITRA BERAS MENGGUNAKAN
ALGORITMA MULTI-SVM DAN NEURAL NETWORK PADA
SEGMENTASI K-MEANS**



TESIS

**Diajukan sebagai salah satu syarat untuk memperoleh gelar Magister
Ilmu Komputer (M.Kom)**

RIDAN NURFALAH

14002295

**Program Studi Ilmu Komputer (S2)
Sekolah Tinggi Manajemen Informatika dan Komputer
Nusa Mandiri
Jakarta
2020**

SURAT PERNYATAAN ORISINALITAS DAN BEBAS PLAGIARISME

Yang bertanda tangan di bawah ini :

Nama : Ridan Nurfalih
NIM : 14002295
Program Studi : Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : Image Processing

Dengan ini menyatakan bahwa tesis yang telah saya buat dengan judul: "Identifikasi Citra Beras Menggunakan Algoritma Multi-Svm dan Neural Network Pada Segmentasi K-Means", adalah hasil karya sendiri, dan semua sumber baik yang kutip maupun yang dirujuk telah saya nyatakan dengan benar dan tesis belum pernah diterbitkan atau dipublikasikan dimanapun dan dalam bentuk apapun.

Demikianlah surat pernyataan ini saya buat dengan sebenar-benarnya. Apabila dikemudian hari ternyata saya memberikan keterangan palsu dan atau ada pihak lain yang mengklaim bahwa skripsi yang telah saya buat adalah hasil karya milik seseorang atau badan tertentu, saya bersedia diproses baik secara pidana maupun perdata dan kelulusan saya dari Program Studi Ilmu Komputer (S2) Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri dicabut/dibatalkan.

Jakarta, 4 Agustus 2020

Yang menyatakan,



Ridan Nurfalih

HALAMAN PERSETUJUAN DAN PENGESAHAN TESIS

Tesis ini diajukan oleh:

Nama : Ridan Nurfalalah
 NIM : 14002295
 Program Studi : Ilmu Komputer
 Jenjang : Strata Dua (S2)
 Konsentrasi : *Image Processing*
 Judul Tesis : Identifikasi Citra Beras Menggunakan Algoritma Multi-svm Dan Neural Network Pada Segmentasi K-means

Telah dipertahankan pada periode 2020-1 dihadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh Magister Ilmu Komputer (M.Kom) pada Program Studi Ilmu Komputer (S2) Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri (STMIK Nusa Mandiri).

Jakarta, 18 Agustus 2020

PEMBIMBING TESIS

Pembimbing I : Dr. Dwiza Riana, S.Si, MM,
M.Kom



Pembimbing II : Anton, M.Kom.



DEWAN PENGUJI

Penguji I : Dr. Windu Gata, M.Kom



Penguji II : Dr. Agus Subekti, M.T



Penguji III /
Pembimbing I : Dr. Dwiza Riana, S.Si, MM,
M.Kom





LEMBAR BIMBINGAN TESIS

STMIK NUSA MANDIRI

NIM : 14002295
Nama Lengkap : Ridan Nurfalalah
Dosen Pembimbing I : Dr. Dwiza Riana, S.Si, MM, M.Kom
Judul Tugas Akhir : "Identifikasi Citra Beras Menggunakan Algoritma Multi SVM dan Neural Network Pada Segmentasi K-Means"

No	Tanggal Bimbingan	Pokok Bahasan	Paraf Dosen Pembimbing
1.	2 April 2020	Pengajuan Judul Tesis	<i>Dwiza Riana</i>
2.	30 Mei 2020	BAB I via ZOOM Meeting	<i>Dwiza Riana</i>
3.	2 Juni 2020	BAB I dan roses akuisi citra	<i>Dwiza Riana</i>
4.	15 Juni 2020	Progres Program MATLAB dan Proses Ekstraksi Diri	<i>Dwiza Riana</i>
5.	16 Juni 2020	Pengajuan Hasil Algoritma untuk Identifikasi	<i>Dwiza Riana</i>
6.	27 Juni 2020	Progres Program MATLAB dan Metode Penelitian via RAPAT Apps	<i>Dwiza Riana</i>
7.	11 Juli 2020	BAB II dan Penjelasan Novelthy	<i>Dwiza Riana</i>
8.	24 Juli 2020	BAB III	<i>Dwiza Riana</i>
9.	30 Juli 2020	BAB IV dan BAB V	<i>Dwiza Riana</i>

Catatan untuk Dosen Pembimbing.

Bimbingan Tesis

- Dimulai pada tanggal : 2 April 2020
- Diakhiri pada tanggal : 30 Juli 2020
- Jumlah pertemuan bimbingan : 9 (Delapan) kali bimbingan

Disetujui oleh,
Dosen Pembimbing

(Dr. Dwiza Riana, S.Si, M.M, M.Kom)



LEMBAR BIMBINGAN TESIS

STMIK NUSA MANDIRI

NIM : 14002295
Nama Lengkap : Ridan Nurfalih
Dosen Pembimbing II: Anton, M.Kom
Judul Tugas Akhir : “Identifikasi Citra Beras Menggunakan Algoritma Multi SVM dan Neural Network Pada Segmentasi K-Means”

No	Tanggal Bimbingan	Pokok Bahasan	Paraf Dosen Pembimbing
1	2 April 2020	Pengajuan Judul Tesis	
2	30 Mei 2020	BAB I via ZOOM Meeting	
3	4 Juni 2020	BAB I via Trello	
4	10 Juni 2020	Revisi BAB I dan Program MATLAB	
5	1 Juli 2020	Pengajuan BAB II	
6	27 Juni 2020	Revisi BAB II dan Pengajuan BAB III	
7	29 Juli 2020	BAB III revisi dan BAB IV	
8	30 Juli 2020	BAB IV revisi dan Pengajuan BAB V	

Catatan untuk Dosen Pembimbing.

Bimbingan Tesis

- Dimulai pada tanggal : 2 April 2020
- Diakhiri pada tanggal : 30 Juli 2020
- Jumlah pertemuan bimbingan : 8 (Delapan) kali bimbingan

Disetujui oleh,
Dosen Pembimbing

(Anton, M.Kom)

KATA PENGANTAR

Puji dan syukur penulis panjatkan kehadiran Tuhan Yang Maha Esa atas berkah dan rahmat-Nya penulis dapat menyelesaikan laporan tesis ini dengan judul “Identifikasi Citra Beras Menggunakan Algoritma Multi-SVM dan Neural Network Pada Segmentasi K-Means”. Penulisan laporan tesis ini dibuat sebagai salah satu syarat kelulusan program Strata Dua (S2) Program Studi Ilmu Komputer STMIK Nusa Mandiri.

Penulisan laporan tesis ini diambil berdasarkan hasil penelitian yang dilakukan pada cira butir beras berjumlah 90 citra yang selanjutnya dilakukan pemrosesan mulai dari konversi citra, segmentasi ekstraksi fitur sampai pada tahap identifikasi jenis dari citra beras tersebut.

Selama penulisan laporan tesis ini penulis banyak menemukan hambatan dan kesulitan, namun berkat doa dan dukungan dari berbagai pihak penulis dapat menyelesaikan laporan tesis ini tepat pada waktunya. Dengan selesainya penulisan tesis ini, penulis mengucapkan terima kasih kepada:

1. Ketua STMIK Nusa Mandiri.
2. Wakil Ketua STMIK Nusa Mandiri.
3. Ketua Program Studi Ilmu Komputer STMIK Nusa Mandiri.
4. Ibu Dr. Dwiza Riana, S.Si, M.M, M.Kom selaku Dosen Pembimbing I dalam penyusunan laporan tesis ini.
5. Bapak Anton, M.Kom selaku Dosen Pembimbing II.
6. Bapak/ Ibu dosen Program Studi Ilmu Komputer (S2) STMIK Nusa Mandiri yang telah memberikan penulis pembelajaran dengan semua bahan yang diperlukan.
7. Staff / karyawan / dosen di lingkungan STMIK Nusa Mandiri.
8. Rekan mahasiswa / mahasiswi STMIK Nusa Mandiri.
9. Orang tua tercinta yang selalu memberikan dorongan dan dukungan materil maupun imateril sehingga penulis dapat menyelesaikan penulisan laporan tesis ini.
10. Dan lain-lain.

Penulis menyadari penulisan tesis ini jauh dari kesempurnaan, untuk itu penulis berharap kritik dan saran yang membangun untuk perbaikan tesis ini dan penulisan tesis di masa yang akan datang. Semoga penulisan tesis ini memberikan manfaat yang sebesar-besarnya untuk pembaca dan penulis pada umumnya.

Jakarta, 4 Agustus 2020

Ridan Nurfalah
Penulis

**SURAT PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH
UNTUK KEPENTINGAN AKADEMIS**

Yang bertanda tangan di bawah ini :

Nama : Ridan Nurfalah
NIM : 14002295
Program Studi : Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : Image Processing
Jenis Karya : Tesis

Demi pengembangan ilmu pengetahuan, dengan ini menyetujui untuk memberikan izin kepada pihak Program Studi Ilmu Komputer (S2) Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri (STMIK Nusa Mandiri) **Hak Bebas Royalti Non-Eksklusif (Non-exclusive Royalti-Free Right)** atas karya ilmiah kami yang berjudul : “Identifikasi Citra Beras Menggunakan Algoritma Multi-SVM dan Neural Network Pada Segmentasi K-Means” beserta perangkat yang diperlukan (apabila ada).

Dengan **Hak Bebas Royalti Non-Eksklusif** ini pihak STMIK Nusa Mandiri berhak menyimpan, mengalih-media atau bentuk-kan, mengelolanya dalam pangkalan data (database), mendistribusikannya dan menampilkan atau mempublikasikannya di internet atau media lain untuk kepentingan akademis tanpa perlu meminta izin dari kami selama tetap mencantumkan nama kami sebagai penulis/pencipta karya ilmiah tersebut.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak STMIK Nusa Mandiri, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini saya buat dengan sebenarnya.

Jakarta, 4 Agustus 2020

Yang menyatakan,




Ridan Nurfalah

ABSTRAK

Nama : Ridan Nurfalalah
NIM : 14002295
Program Studi : Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : Image Processing
Judul : “Identifikasi Citra Beras Menggunakan Algoritma *Multi-SVM* dan *Neural Network* pada Segmentasi *K-Means*”

Indonesia merupakan negara dengan kebutuhan beras yang tinggi karena menjadi makanan pokok lebih dari 90% masyarakatnya. Kebutuhan tinggi memerlukan stok yang tinggi sehingga impor pun dilakukan dengan aturan-aturan sesuai Permendagri Nomor 19/M-DAG/PER/3/2014 yang menerangkan standar impor beras. Terdapat banyak jenis beras yang di impor ke Indonesia dengan berbagai kualitas, warna dan keperluan impor seperti untuk kesehatan atau stabilisasi harga. Dari sisi wana, beras putih impor merupakan beras paling banyak dikonsumsi oleh warga Indonesia. Salahsatu contohnya adalah beras melati (*jasmine*) dari Thailand. Sedangkan dari sisi keperluan impor baik untuk kesehatan dan stabilisasi harga beras japonica (Jepang) dan Basmati (Pakistan) merupakan jenis paling banyak di impor ke Indonesia. Namun masih banyak yang belum mengenal ketiga beras tersebut. Pada penelitian ini dilakukan identifikasi ketiga jenis beras tersebut dengan perbandingan algoritma *Multi-SVM* dan *Neural Network*. Akuisisi citra dilakukan menggunakan *flatbed scanner* yang menghasilkan 90 citra yang dibagi menjadi 63 citra training dan 27 citra testing. *K-Means* menjadi metode segmentasi citra dan mengubah citra menjadi citra biner. Ekstraksi fitur menggunakan morphological feature dengan metode *regionprop* dikombinasikan dengan *Gray Level Co-Occurence Matrix* (GLCM) menghasilkan 9 fitur yang dapat menghasilkan akurasi 96,296% untuk *Multi-SVM* dan *Neural Network* 88,89%.

Kata Kunci: *K-Means*, GLCM, *Regionprop*, Citra Beras, Identifikasi

ABSTRACT

Name : Ridan Nurfalah
NIM : 14002295
Study of Program : Computer Science
Levels : Strata Dua (S2)
Concentration : Image Processing
Title : “*Rice Image Identification Using Multi-SVM Algorithms and Neural Networks in K-Means Segmentation*”

Indonesia is a country with high rice needs because it is a staple food for more than 90% of populations. High demand requires high stock so imports are carried out in accordance with Permendagri Number 19/M-DAG/PER/3/2014 which explains rice import standards. There are many types of rice imported into Indonesia with various quality, color and import requirements such as for health or price stabilization. In terms of colors, imported white rice is the most consumed rice by Indonesians. One example is jasmine rice from Thailand. Meanwhile, in terms of imports, both for health and stabilizing the price of japonica rice (Japan) and Basmati (Pakistan) are the most imported to Indonesia. But there are still many who are not familiar with those three rices. In this research, the three types of rice were identified by comparing the Multi-SVM algorithm and Neural Network algorithm. Image acquisition is done using a flatbed scanner which produces 90 images divided into 63 training images and 27 testing images. K-Means becomes an image segmentation method and image binary converts. Feature extraction using morphological features with the regionprop method combined with the Gray Level Co-Occurrence Matrix (GLCM) produces 9 features that can produce 96.296% accuracy for Multi-SVM and 88.89% Neural Network.

Keyword: K-Means, GLCM, Regionprop, Rice Image, Identification

DAFTAR ISI

	Halaman
HALAMAN SAMPUL	i
HALAMAN JUDUL	ii
SURAT PERNYATAAN ORISINALITAS DAN BEBAS PLAGIARISM...	iii
PERSETUJUAN TESIS	iv
PERSETUJUAN DAN PENGESAHAN	v
LEMBAR BIMBINGAN TESIS	vi
KATA PENGANTAR	viii
SURAT PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS	x
ABSTRAK	xi
ABSTRACT.....	xii
DAFTAR ISI	xiii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xvi
DAFTAR LAMPIRAN	xvii
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Identifikasi Masalah	3
1.3. Tujuan Penelitian	3
1.4. Ruang Lingkup Penelitian	4
1.5. Sistematika Penulisan	4
BAB II LANDASAN PEMIKIRAN	6
2.1. Tinjauan Pustaka	6
2.1.1. Akuisisi Citra	6
2.1.2. <i>Flatbed Scanning</i>	6
2.1.3. Pra-pemrosesan Citra	8
2.1.4. Segmentasi Citra	9
2.1.5. <i>K-Means Clustering</i>	10
2.1.6. Konversi Biner	11
2.1.7. Dataset	11
2.1.8. <i>Gray Level Co-Occurance Method (GLCM)</i>	12
2.1.9. <i>Regionprops</i>	15
2.1.10. Multi-SVM	19
2.1.11. Neural Network	21
2.1.12. Pengukuran <i>Confusion Matrix</i>	24
2.2. Tinjauan Studi	25
BAB III METODOLOGI PENELITIAN	31
3.1. Perancangan Penelitian	31
3.2. Objek Penelitian	32

3.3. Pengumpulan Data	32
3.4. Pengolahan Data Awal	32
3.4.1. Akuisisi Citra	38
3.4.2. Image Processing	39
3.5. Metode Yang Diusulkan	41
3.6. Eksperimen dan Pengujian Metode	42
3.7. Evaluasi dan Validasi	44
BAB IV HASIL PENELITIAN DAN PEMBAHASAN	45
4.1. Hasil Penelitian	45
4.2. Ekstraksi Ciri	49
4.3. Hasil Identifikasi	53
4.4. Evaluasi dan Validasi Hasil	56
4.5. Hasil Komparasi Algoritma Multi-SVM dan Neural Network	59
BAB V PENUTUP	61
5.1. Kesimpulan	61
5.2. Saran	62
DAFTAR REFERENSI	63
DAFTAR RIWAYAT HIDUP.....	68
LAMPIRAN-LAMPIRAN.....	69

DAFTAR GAMBAR

Halaman

Gambar 2.1 Overview operasi <i>flatbed scanning</i> (a) dan citra hasil pindai(b).....	7
Gambar 2.2 Proses Flatbed Scanning Citra Beras Malaysia	8
Gambar 2.3 Hasil Flatbed Scanning Citra Beras Malaysia.....	8
Gambar 2.4 Ilustrasi Perhitungan Eksentrisitas	14
Gambar 2.5 Representasi regionprops dengan pendekatan persegi panjang	17
Gambar 2.6 Representasi regionprops dengan pendekatan elips	17
Gambar 2.7 Representasi Perimeter	18
Gambar 2.8 Sampel Dipisahkan Secara Linear dalam Hyperplane	20
Gambar 2.9 Arsitektur Neural Network.....	24
Gambar 3.1 Model Penelitian	31
Gambar 3.2 (a) beras jasmine, (b) beras japonica, (c) beras basmati.....	32
Gambar 3.3 Akuisisi Citra	38
Gambar 3.4 Matrix Grayscale Citra basmati1	40
Gambar 3.5 Matrix Grayscale Citra japonica1	41
Gambar 3.6 Matrix Grayscale Citra jasmine1	41
Gambar 4.1 Nilai Ciri Perbutir Basmati	49
Gambar 4.2 Nilai Ciri Perbutir Japonica	50
Gambar 4.3 Nilai Ciri Perbutir Jasmine	52
Gambar 4.4 Diagram Hasil Komparasi.....	60

DAFTAR TABEL

	Halaman
Tabel 2.1 Spesifikasi dataset citra butir beras impor	12
Tabel 2.2 <i>Confusion Matrix</i>	24
Tabel 2.3 Penelitian Sebelumnya.....	28
Tabel 3.1 Dataset Butir Beras	33
Tabel 3.2 Data Training Butir Beras	35
Tabel 3.3 Data Testing Butir Beras.....	36
Tabel 3.4 Konversi Citra RGB ke Grayscale.....	40
Tabel 4.1 segmentasi Citra Beras dengan K-Means	45
Tabel 4.2 Segmentasi Citra Butir Beras Basmati.....	46
Tabel 4.3 Segmentasi Citra Butir Beras Japonica.....	47
Tabel 4.4 Segmentasi Citra Butir Beras Jasmine.....	48
Tabel 4.5 Nilai Ciri Basmati	50
Tabel 4.6 Nilai Ciri Japonica	51
Tabel 4.6 Nilai Ciri Jasmine	52
Tabel 4.7 Identifikasi Citra Beras Basmati	53
Tabel 4.8 Identifikasi Citra Beras Japonica	54
Tabel 4.9 Identifikasi Citra Beras Jasmine	55
Tabel 4.10 Penjabaran Citra Teridentifikasi dengan Multi-SVM.....	56
Tabel 4.11 Penjabaran Citra Teridentifikasi dengan Neural Network.....	57
Tabel 4.12 Hasil Identifikasi Citra dengan Multi-SVM.....	57
Tabel 4.13 Hasil Identifikasi Citra dengan Neural Network.....	58
Tabel 4.14 Hasil Komparasi	59

DAFTAR LAMPIRAN

	Halaman
Lampiran 1 Dataset Citra Butir Beras	69
Lampiran 2 Tampilan Antar Muka GUI MATLAB	71
Lampiran 3 Coding Konversi RGB ke Grayscale	72
Lampiran 4 Coding Segmentasi K-Means	72
Lampiran 5 Coding Konversi Biner	73
Lampiran 6 Coding Ekstraksi Fitur (Tampil Gambar)	73
Lampiran 7 Coding Ekstraksi Fitur (Tampil Tabel)	74
Lampiran 8 Coding Multi-SVM	75
Lampiran 9 Coding Neural Network	75

BAB I

PENDAHULUAN

1.1. Latar Belakang

Pangan memiliki peran penting dalam kehidupan makhluk hidup, terutama manusia. Tanpa pangan makhluk hidup tidak akan bisa mempertahankan kelangsungan hidupnya[1]. Salah satu kebutuhan pangan kehidupan manusia adalah beras. Beras merupakan kebutuhan vital untuk kehidupan setengah penduduk dunia terutama di beberapa negara Asia, seperti negara Indonesia[2].

Menurut Departemen Pertanian Amerika Serikat (USDA) Indonesia termasuk kedalam 5 besar negara importir dan konsumen terbesar di dunia[3]. Rata-rata total konsumsi beras domestik dunia sebesar 7,88% yaitu 37,970 juta ton pertahun pada 2015-2019[4]. Menurut hasil survey Pusat Data dan Informasi Pertanian (Pusdatin) pada tahun 2002-2018 lebih dari 90% penduduk Indonesia mengkonsumsi beras. Berdasarkan SUSENAS-BPS rata-rata konsumsi beras di Indonesia perkapitanya pada tahun 2002-2018 mencapai 96,33 kg/kapita/tahun. Pusdatin memprediksi berdasarkan model trend kuadratik ($MAPE=1,21175$) konsumsi beras pada tahun 2019 mencapai 97,0545 kg/kapita/tahun dan tahun 2020 mencapai 96,9430 kg/kapita/tahun[4].

Melihat tingginya konsumsi beras di Indonesia, maka diperlukan stok beras yang berkualitas untuk dikonsumsi masyarakat, impor beras dari beberapa negarapun dilakukan pemerintah. Badan Pusat Statistik (BPS) mencatat pada tahun 2018 Thailand merupakan negara dengan jumlah impor beras terbesar yaitu 795.600,1 ton/tahun dan pada tahun 2019 beralih menjadi Pakistan negara paling banyak melakukan impor beras ke Indonesia dengan jumlah 182.564,9 ton/tahun selain itu ada juga negara lain yang melakukan ekspor ke Indonesia termasuk Jepang dengan total 93,7 ton/tahun pada tahun 2019[5].

Menurut Peraturan Menteri Perdagangan Republik Indonesia Nomor 19/M-DAG/PER/3/2014 terdapat banyak jenis beras impor yang datang ke Indonesia yang ditinjau dari berbagai kualitas, warna dan keperluan impor seperti untuk kesehatan atau stabilisasi harga[6]. Dari sisi wana, beras putih merupakan beras

paling banyak dikonsumsi oleh warga Indonesia[7]. Salahsatu contoh beras putih impor yang banyak dikonsumsi adalah beras melati (*jasmine*) dari Thailand. Sedangkan dari sisi keperluan impor baik untuk kesehatan dan stabilisasi harga beras japonica (Jepang) dan Basmati (Pakistan) merupakan jenis paling banyak di impor ke Indonesia[8]. *Jasmine* dan basmati merupakan jenis beras dengan keunggulan pada aroma dan sering menjadi acuan satu sama lain[9]. Bedanya, beras jenis basmati secara fisik memiliki tekstur lebih lembut, masa simpan yang lama, dan ekspansi volume selama pemasakan yang ditandai dengan perpanjangan kernel linear dengan tingkat kemekaran biji yang minimum dibanding *jasmine*[10]. Sedangkan, japonica dari fisik lebih kecil dan lengket dengan *diet value* yang lebih tinggi. Namun, masih banyak masyarakat belum mengenal ketiga jenis beras impor ini baik secara fisik maupun kualitas atau nilai gizi.

Perkembangan ilmu pengetahuan dan teknologi mampu mengidentifikasi jenis beras impor tersebut baik dari kualitas, *diet value* dan ciri fisik. Salahsatunya dengan teknologi pengolahan citra yang dapat mendeteksi dari ciri fisik butir beras. Sehingga tidak perlu lagi dilakukan pengenalan jenis beras secara manual yang terkadang tidak konsisten dan hasil yang salah[11]. Namita Patel dan kawan-kawan[11] melakukan pengujian pada butir beras dengan menggunakan atribut fisik dengan *regionprop* meliputi *Area*, *MajorAxisLength*, *MinorAxisLength* dan *Eccentricity*. Namun, penelitian ini hanya diujikan pada satu jenis beras India dan hanya sampai nilai ekstraksi fitur. Phuvin Kongsawat dan kawan-kawan[12] menguji kualitas citra butir beras dengan mengubah citra RGB menjadi citra biner untuk menghasilkan nilai ekstraksi dengan fitur morfologi. Namun penelitian ini hanya sampai ekstraksi fitur tanpa identifikasi jenis beras itu sendiri. David Ricardo[7] dan T.Gayathri Devi[13] menggunakan metode *Gray Level Co-Occurance Method* (GLCM) dalam ekstraksi fitur dan menggunakan algoritma multi-SVM dalam klasifikasi. Namun, hanya diujikan pada citra beras lokal dan dan tekstur fisik batang.

Melihat penelitian sebelumnya mengenai identifikasi citra beras yang hanya terfokus pada satu jenis beras dan menggunakan metode ekstraksi fitur minim, maka pada penelitian ini dilakukan identifikasi citra beras impor Indonesia dari tiga negara penyuplai tertinggi dengan melakukan akuisisi citra sendiri pada ketiga jenis

beras tersebut. Setelah dilakukan akuisisi citra, segmentasi dilakukan dengan menggunakan algoritma K-Means dan konversi citra biner. Untuk ekstraksi fitur menggabungkan dua metode yaitu fitur morfologi meliputi regionprop dan metode *Gray Level Co-Occurance Method* (GLCM). Algoritma Muti-SVM dan *Neural Network* diujikan untuk mengidentifikasi jenis ketiga beras tersebut dan membandingkannya dengan nilai akurasi masing-masing algoritma.

1.2. Identifikasi Masalah

Beberapa identifikasi masalah yang terdapat pada penelitian ini berdasarkan uraian di atas:

1. Apakah algoritma K-Means dan konversi biner dapat melakukan segmentasi dengan baik pada citra butir beras?
2. Apakah metode regionprop yang dikombinasikan dengan GLCM dapat menghasilkan ekstraksi fitur yang baik untuk identifikasi jenis citra butir beras?
3. Apakah algoritma Multi-SVM dan *Neural Network* dapat menghasilkan identifikasi jenis citra butir beras yang baik dengan menggunakan metode ekstraksi fitur regionprop yang dikombinasikan dengan GLCM?
4. Bagaimana perbandingan hasil uji menggunakan algoritma Multi-SVM dan *Neural Network* pada citra butir beras?

1.3. Tujuan Penelitian

Tujuan dilakukan penelitian ini adalah sebagai berikut:

1. Melakukan segmentasi citra beras dengan menggunakan algoritma K-Means dan konversi biner pada citra butir beras.
2. Melakukan analisa efektivitas penggunaan metode regionprop yang dikombinasikan dengan GLCM dalam melakukan ekstraksi fitur untuk identifikasi jenis citra butir beras.
3. Melakukan analisa pada penerapan algoritma Multi-SVM dan *Neural Network* sebagai algoritma yang digunakan untuk identifikasi jenis citra butir beras menggunakan metode ekstraksi fitur regionprop yang dikombinasikan dengan GLCM.

4. Melakukan analisa perbandingan algoritma dengan akurasi tertinggi pada hasil identifikasi jenis citra beras menggunakan Multi-SVM dan *Neural Network*.
5. Selain tujuan penelitian di atas tujuan penulisan laporan tesis ini dibuat sebagai salah satu syarat untuk mendapatkan gelar Magister Ilmu Komputer (M.Kom) pada Program Studi Ilmu Komputer (S2) STMIK Nusa Mandiri.

1.4. Ruang Lingkup Penelitian

Ruang lingkup penelitian merupakan pembatasan masalah yang dilakukan pada penelitian ini guna mencapai hasil penelitian yang sesuai dengan tujuan dan fokus penelitian pada identifikasi jenis beras impor dengan menggunakan parameter morfologi regionprop dan *Gray Level Co-Occurance Method* (GLCM) dengan segmentasi K-Means dan konversi biner serta perbandingan akurasi algoritma Multi-SVM dan *Neural Network* pada klasifikasi. Data yang digunakan adalah citra beras impor dari tiga negara importir Indonesia yaitu basmati, jasmine dan japonica. Akuisisi citra dengan metode *Flatbed Scanning* (FBS) dan pengembangan aplikasi menggunakan MATLAB.

1.5. Sistematika Penulisan

Sistematika penulisan pada penelitian ini terdiri dari 5 (lima) bab, dimana tiap bab terdiri dari beberapa sub bab sebagai berikut:

BAB 1 PENDAHULUAN

Pada Bab ini membahas tentang Latar Belakang Penulisan, Identifikasi Masalah, Tujuan Penelitian, Ruang Lingkup Penelitian, Hipotesis dan Sistematika Penulisan.

BAB 2 LANDASAN / KERANGKA PEMIKIRAN

Pada bab ini dibahas teori yang melandasi penelitian ini, pembahasan penelitian sebelumnya yang digunakan untuk mengetahui sejauh mana penelitian yang telah dilakukan sebelumnya sebagai landasan teori dilakukannya penelitian ini.

BAB 3 METODOLOGI PENELITIAN

Pada bab ini menjelaskan tentang perancangan penelitian diantaranya adalah metode pengumpulan data, metode yang diusulkan, eksperimen dan pengujian metode serta evaluasi dan validasi hasil.

BAB 4 HASIL PENELITIAN DAN PEMBAHASAN

Pada bab ini menampilkan hasil penelitian berupa hasil dari segmentasi, nilai tekstur yang dihasilkan oleh metode analisa tekstur, implementasi metode analisa tekstur, dan hasil klasifikasi akhir pada program dan hasil keseluruhan

BAB 5 PENUTUP

Pada bab ini membahas kesimpulan dari penelitian, kekurangan & kelebihan dari model yang digunakan, serta saran yang diberikan untuk penelitian selanjutnya.

BAB II

LANDASAN PEMIKIRAN

2.1. Tinjauan Pustaka

Pada penelitian ini penulis menggunakan referensi dari berbagai buku, jurnal dan literatur lainnya yang dituangkan pada bagian landasan pemikiran untuk mendukung penelitian yang dilakukan dalam identifikasi jenis beras impor menggunakan citra butir beras.

2.1.1. Akuisisi Citra

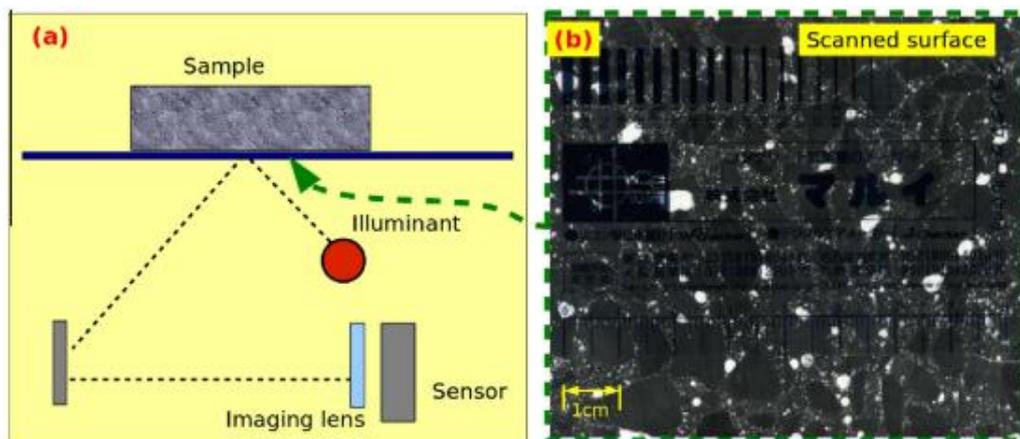
Akuisisi citra merupakan suatu proses dimana kita memperoleh representasi digital dari suatu objek atau *scene*. Representasi ini dikenal sebagai citra dan elemen-elemen yang membentuknya disebut piksel (elemen citra)[14]. Terdapat banyak cara dalam akuisisi atau pembentukan suatu citra digital. Secara umum, citra dibentuk oleh suatu peristiwa dimana cahaya dalam spektrum yang terlihat jatuh pada sebagian permukaan reflektif, sebagian menyerap, dengan foton yang tersebar dikumpulkan di lensa kamera dikonversi menjadi sinyal listrik baik dengan tabung vakum atau *Charge-Couple Device* (CCD)[15]. Dalam praktiknya, teknik ini hanya satu dari banyak cara dalam pembentukan atau akuisisi citra digital. Teknik lain seperti *thermal*, ultrasonik, sinar-x, gelombang radio, *flatbed scanning* dan lainnya semua dapat menghasilkan citra.

2.1.2. Flatbed Scanning

Shveta Mahajan dan kawan-kawan melakukan teknik akuisisi citra dengan teknik *flatbed scanning* dalam penelitiannya tentang pengujian kualitas legum[16]. Menurut Shveta dkk mekanisme dasar flatbed scanner melibatkan sensor citra yang meluncur di sepanjang jendela kaca, dimana objek yang akan dipindai ditempatkan. Objek yang dicitrakan diterangi oleh lampu. Kepala pindai yang terdiri dari cermin, lensa, filter dan susunan *Charge-Couple Device* (CCD), dipindahkan di bawah objek menggunakan mekanisme bermotor. Pemindai menggunakan pengaturan dua cermin atau tiga cermin untuk memantulkan citra objek pada lensa, yang

memfokuskan hal yang sama ke susunan *Charge-Couple Device* (CCD) melalui filter.

Zhendi Wang dan kawan-kawan juga melakukan penelitian pada *Frost-Damage Concrete* (FDC) yaitu kerusakan beton akibat es dengan menggunakan flatbed scanner[17]. Flatbed scanner beroperasi dengan menggunakan perangkat *Charge-Couple Device* (CCD). Ketika *Charge-Couple Device* (CCD) digerakkan oleh motor stepper listrik, melintasi di bawah pelat muka kaca pemindai, citra digital dari setiap benda datar yang ditempatkan pada pelat dikumpulkan dengan cepat melalui sistem cermin yang tergabung dengan kepala traverse yang sempit, seperti yang dijelaskan pada Gambar 2.1 berikut:



Sumber: [17]

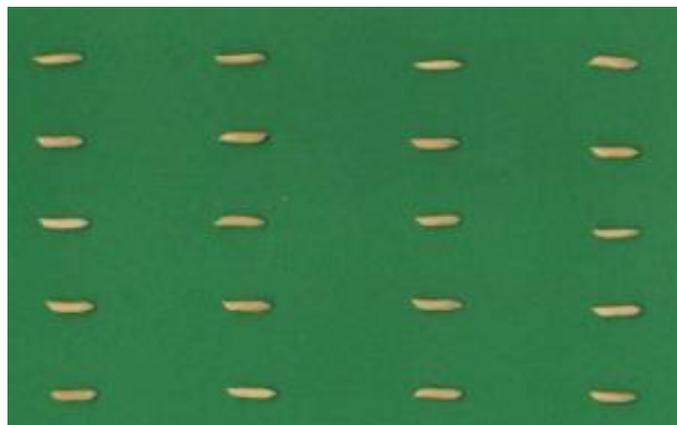
Gambar 2.1 Overview operasi *flatbed scanning*(a) dan citra hasil pindai(b)

Teknik flatbed scanning juga diaplikasikan oleh Ruslan dkk[18] dalam akuisisi citra butir beras Malaysia untuk ekstraksi fitur morfologi citra beras tersebut. Akuisisi citra dilakukan seperti pada Gambar 2.2 warna hijau neon digunakan sebagai latar belakang citra yang memberikan kontras tertinggi antara benih dan latar belakang. Resolusi citra diatur ke 600 dpi dan disimpan dalam format *Joint Photographic Expert Group* (JPEG) seperti pada Gambar 2.3. Citra diolah lebih lanjut menggunakan aplikasi LabVIEW untuk ekstraksi fitur morfologi.



Sumber : [18]

Gambar 2.2 Proses *Flatbed Scanning* Citra Beras Malaysia



Sumber : [18]

Gambar 2.3 Hasil *Flatbed Scanning* Citra Beras Malaysia

2.1.3. Pra-pemrosesan Citra

Sebelum dilakukan pemrosesan citra lebih lanjut, untuk mengurangi distraksi warna berlebih dan mempermudah dalam segmentasi maka dilakukan pra-pemrosesan citra. Pra-pemrosesan citra bertujuan untuk memfasilitasi tahapan pemrosesan selanjutnya dengan memberikan input yang memenuhi asumsi penyederhanaan tertentu[19]. Citra butir beras yang diakuisisi menggunakan flatbed scanner menghasilkan citra RGB dengan komposisi tiga lapisan warna yaitu merah, hijau dan biru dimana setiap lapisan memiliki angka yang mewakili intensitas[20]. Untuk mengurangi layer tersebut agar mudah dalam pendeteksian

objek dan latar belakang citra maka citra hasil akuisisi dilakukan pra-pemrosesan dengan mengubahnya menjadi citra skala abu-abu (*grayscale*).

Citra skala abu-abu merupakan citra digital yang hanya memiliki satu nilai kanal pada setiap pixelnya, dengan kata lain nilai bagian RED=GREEN=BLUE. Nilai tersebut digunakan untuk menunjukkan tingkat intensitas. Warna yang dimiliki adalah warna hitam, keabuan, dan putih. Tingkatan keabuan disini merupakan warna abu dengan berbagai tingkatan dari hitam hingga mendekati putih[21]. Konversi citra berwarna menjadi skala abu-abu telah dilakukan sejak lama karena alasan praktis: untuk membuat citra berwarna pada layar dan printer hitam putih; serta karena alasan artistik. Konversi citra dari berwarna ke skala abu-abu (*grayscale*) yaitu pengurangan dari tiga dimensi menjadi ruang warna satu dimensi [22]. Pada penelitian ini penulis fokus pada mengubah citra menjadi *grayscale*, karena konversi ini dapat membedakan antara citra objek dan latar belakang citra dengan perhitungan sebagai berikut[23]:

$$g(x,y) = 0.2989 \times R + 0.5878 \times G + 0.1140 \times B \quad (1)$$

Dimana R adalah merah, G adalah hijau dan B adalah biru yang ketiga elemen tersebut merupakan komponen dari citra berwarna.

2.1.4. Segmentasi Citra

Segmentasi adalah teknik klasifikasi unsupervise yang mengatur pola dalam kelompok atau wilayah suatu citra. Metode pertama adalah mempartisi citra berdasarkan perubahan intensitas yang langsung, seperti tepi pada citra. Metode kedua didasarkan pada partisi citra menjadi daerah yang serupa sesuai dengan kriteria yang telah ditentukan[24]. Segmentasi citra dianggap sebagai langkah kunci untuk fase representasi / pengenalan citra selanjutnya menjadi representasi citra yang lebih bermakna dan lebih mudah untuk dianalisis[25].

Segmentasi citra merupakan metodologi kritis dalam transformasi citra dan pemahaman citra dalam pemrosesan citra digital. Teknik ini pada dasarnya digunakan untuk memisahkan citra menjadi beberapa bagian homogenitas. Motif pembagian citra adalah untuk meningkatkan representasi citra menjadi sesuatu yang lebih penting. Penggunaan dasar itu adalah untuk menemukan lokasi objek, tepi, garis dll dalam citra digital[26].

Pada penelitian ini dilakukan segmentasi citra dengan menggunakan algoritma K-Means dan mengubahnya menjadi citra biner.

2.1.5. *K-Means Clustering*

K-Means melakukan identifikasi dengan mengklasifikasikan set data yang diberikan sesuai dengan kriteria yang diberikan dalam memberikan segmentasi ruang instance, ke dalam wilayah objek yang sama[27].

Clustering adalah metode untuk membagi satu set data menjadi sejumlah kelompok tertentu, salah satu metode yang populer adalah *K-Means Clustering*. K-Means memecah kumpulan data menjadi sekelompok data nomor k , lalu mengklasifikasikan satu set data yang diberikan ke jumlah cluster disjoint k . Algoritma K-means terdiri dari dua fase terpisah. Pada fase pertama menghitung k centroid dan pada fase kedua dibutuhkan setiap titik ke cluster yang memiliki centroid terdekat dari titik data masing-masing. Ada berbagai metode untuk menentukan jarak centroid terdekat dan salah satu metode yang paling sering digunakan adalah jarak Euclidean. Setelah pengelompokan selesai, selanjutnya menghitung ulang centroid baru dari masing-masing cluster dan berdasarkan centroid itu, jarak Euclidean baru dihitung antara setiap pusat dan setiap titik data dan menetapkan titik-titik dalam cluster yang memiliki jarak Euclidean minimum. Setiap cluster di partisi ditentukan oleh objek anggotanya dan oleh centroid-nya. Centroid untuk setiap kluster adalah titik di mana jumlah jarak dari semua objek di kluster tersebut diminimalkan. Jadi K-means adalah suatu algoritma iteratif dimana meminimalkan jumlah jarak dari setiap objek ke cluster centroid-nya, di atas semua cluster[28].

Sebuah citra dengan resolusi $x \times y$ dan citra tersebut harus terkluster ke dalam cluster k . $p(x,y)$ menjadi piksel input untuk dijadikan cluster dan c_k menjadi cluster center. Algoritma untuk pengelompokan K-Means adalah sebagai berikut:

1. Inisialisasi jumlah cluster k dan cluster center.
2. Untuk setiap piksel citra, hitung jarak Euclidean d , antara tengah dan setiap piksel citra menggunakan relasi yang diberikan di bawah ini.

$$d = \| p(x, y) - c_k \| \quad (2)$$

3. Tetapkan semua piksel ke center terdekat berdasarkan jarak d .

- Setelah semua piksel ditetapkan, hitung ulang posisi baru pusat menggunakan hubungan yang diberikan di bawah ini.

$$c_k = \frac{1}{k} \sum_{y \in c_k} \sum_{x \in c_k} p(x, y) \quad (3)$$

- Ulangi proses ini hingga memenuhi toleransi atau nilai kesalahan.
- Bentuk kembali piksel kluster pada citra.

Selain dengan cara diatas, bisa juga disederhanakan dengan algoritma K-Means berikut[29] :

$$d_y = \sqrt{\sum_{k=1}^n (x_{ik} - x_{jk})^2} \quad (4)$$

- Iterasi ke-1. Pusat – pusat gugusan ditetapkan secara acak. Piksel – piksel akan ditempatkan ke pusat – pusat terdekat.
- Iterasi ke-2. Setiap pusat – pusat gugusan berpindah/bergerak ke pusat tengah rataan, semua pikselnya.
- Iterasi ke-n. Semua pusat gugusan telah stabil.

2.1.6. Konversi Biner

Citra biner merupakan citra yang memiliki piksel dengan hanya dua kemungkinan nilai intensitas yang biasanya ditampilkan sebagai hitam dan putih. Secara numerik, kedua nilai tersebut adalah 0 untuk hitam dan 1 atau 255 untuk putih. Citra biner seringkali diproduksi dengan melakukan *thresholding* pada citra *grayscale* atau citra warna untuk memisahkan objek dalam citra dari latar belakang. Warna objek (biasanya putih) disebut sebagai warna latar depan. Sisanya (biasanya hitam) disebut sebagai warna latar belakang. Namun, polaritas ini mungkin terbalik tergantung pada citra yang akan mengalami ambang. Ketika polaritas terbalik, objek ditampilkan dengan 0 sedangkan latar belakang memiliki nilai bukan nol[30].

Ada dua alasan utama dalam melakukan konversi citra biner. Pertama, citra biner memiliki representasi yang kompak. Kedua, citra dapat dicocokkan secara efisien menggunakan opsi yang disediakan oleh set instruksi prosesor modern[31].

2.1.7. Dataset

Dataset merupakan kumpulan data yang berelasi atau berkaitan satu dengan lainnya dalam satu kesatuan yang biasanya bersifat spesifik terhadap suatu kasus

tertentu. Dataset dipergunakan sebagai referensi data yang valid untuk suatu penelitian selanjutnya, misalnya untuk referensi data dalam pembelajaran sistem cerdas (sistem pemrosesan citra, pengenalan pola, machine learning, dan lain-lain), atau juga sebagai referensi data dalam pengujian sistem otomatis seperti misalnya pada sistem klasifikasi, klusterisasi, dan sentimen analisis. Dataset yang baik memiliki ciri memiliki data yang lengkap, selalu up to date, bersifat konsisten dalam representasi datanya, jumlah variabelnya jelas, tidak mengandung noise, menarik, dan mudah dimengerti[32].

Pada penelitian ini dataset citra yang digunakan merupakan dataset private dengan digitalisasi dan akuisisi citra menggunakan metode *flatbed scanning* dengan objek butir beras impor dari tiga negara yaitu beras jenis basmati, jasmine dan japonica. Ketiga jenis beras tersebut menjadi kelas yang menandakan varietas pada identifikasi penelitian. Berikut pada Tabel 2.1 adalah spesifikasi dataset citra butir beras impor:

Tabel 2.1 Spesifikasi dataset citra butir beras impor

Jenis Beras Impor	Jumlah Data
Basmati	30
Jasmine	30
Japonica	30
Total	90

Dataset citra pada Tabel 2.1 dibagi ke dalam dua bagian, yaitu data training dan data testing. Data training adalah seperangkat data awal yang digunakan untuk membantu program memahami bagaimana menerapkan teknologi seperti jaringan saraf untuk belajar dan menghasilkan hasil yang canggih. Data tersebut mungkin dilengkapi dengan set data selanjutnya yang disebut set validasi dan pengujian[33]. Sedangkan data training berisi data baru yang akan diklasifikasikan oleh model yang telah dibuat dan akurasi klasifikasi dievaluasi[34].

2.1.8. *Gray Level Co-Occurance Method (GLCM)*

GLCM pertama kali diperkenalkan oleh Haralick pada tahun 1973 dan menjadi salahsatu tekstur ekstraksi fitur yang paling populer dan jangkauan luas sehingga banyak yang menggunakannya. GLCM mencirikan statistik ordo kedua dari suatu citra dengan menghitung seberapa dekat karakteristik piksel dengan nilai-nilai spesifik dan dalam hubungan spasial tertentu terjadi dalam suatu citra. Matriks berisi probabilitas bersyarat dari semua kombinasi pasangan tingkat abu-abu yang diberikan pada jarak perpindahan tertentu (d) dan pada orientasi tertentu (θ). Jarak perpindahan (d) juga dikenal sebagai *interpixel distance*[35]. Probabilitas (P_r) dapat dideklarasikan dengan:

$$P_r(x) = \{C_{ij}|(d, \theta)\} \quad (5)$$

Dimana C_{ij} didefinisikan sebagai:

$$C_{ij} = \frac{P_{ij}}{\sum_{i,j=1}^G P_{ij}} \quad (6)$$

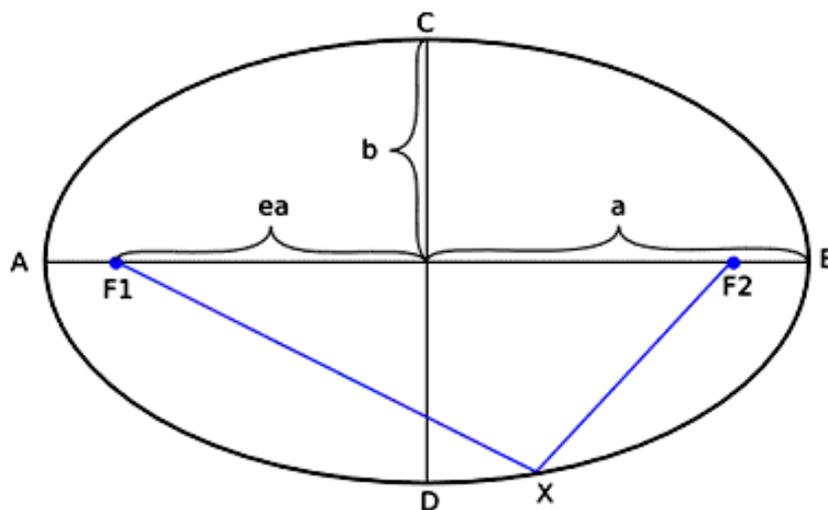
Pada persamaan di atas, variabel C_{ij} mewakili jumlah kemunculan tingkat abu-abu pada baris dan kolom. Nilai P_{ij} adalah nilai probabilitas dari GLCM (berapa kali nilai referensi terjadi dalam kombinasi tertentu dengan piksel tetangga). G adalah jumlah total tingkat abu-abu. Pada contoh tertentu, pada jarak dan orientasi perpindahan tertentu, penjumlahan penyebut dalam persamaan mewakili jumlah total pasangan tingkat abu-abu dalam citra. Fitur yang dihasilkan dengan menghitung fitur untuk masing-masing dari matriks *co-occurance* yang diperoleh dengan menggunakan arah 0° , 45° , dan 135° , lalu hitung nilai rata-rata dari keempat nilai tersebut[35].

GLCM menciptakan *square matrix* dimensi yang sama dengan intensitas maksimum dan disusun oleh frekuensi intensitas abu-abu yang berbeda di dalam tumpukan. Pemrosesan ini dipengaruhi oleh pitch pixel dan arahnya. Dalam pemrosesannya dipilih langkah yang sama dengan satu, yang memungkinkan mempertimbangkan variasi pemrosesan yang lebih halus. Mengenai arahnya, deskriptor yang dihitung untuk keempat sudut (0, 45, 90, 135) dirata-ratakan agar tidak memperhitungkan distribusi geometris pada permukaan material[36].

Terdapat banyak fitur yang dapat di ekstraksi dari metode GLCM. Pada penelitian ini digunakan 4 ekstraksi fitur GLCM, yaitu *eccentricity*, *contrast*, *homogeneity* dan *correlation*.

1. Eksentrisitas (*Eccentricity*)

Eksentrisitas merupakan nilai perbandingan antara jarak *foci ellips minor* dengan *foci ellips mayor* suatu citra. Rentang nilai yang ada pada eksentrisitas adalah antara 0 sampai 1. Objek yang berbentuk memanjang/mendekati bentuk garis lurus, nilai eksentrisitasnya mendekati angka 1, sedangkan objek yang berbentuk *ellips*, nilai eksentrisitasnya mendekati angka 0. Pada Gambar 2.4 diilustrasikan perhitungan eksentrisitas [37]:



Sumber: [37]

Gambar 2.4 Ilustrasi Perhitungan Eksentrisitas

Dengan penjelasan rumus dapat ditulis sebagai berikut:

$$e = \sqrt{1 - \frac{b^2}{a^2}} \quad (7)$$

Dimana:

e = *eccentricity*

a = major axis

b = minor axis

2. Kontras (*Contrast*)

Kontras menunjukkan ukuran distribusi elemen (moment inersia) dari matriks citra. Jika elemen terletak jauh dari diagonal utama, maka nilai kontras akan lebih besar. Hasil perhitungan kontras sehubungan dengan jumlah keragaman intensitas abu-abu yang terkandung dalam citra sampel. Secara visual, nilai kekontrasan adalah ukuran variasi antar derajat keabuan suatu daerah citra[38].

$$Contrast = \sum_{i,k=1}^N P(i,j)(i-j)^2 \quad (8)$$

atau

$$Contrast = \sum_{n=0}^{G-1} n^2 \left\{ \sum_{i=1}^G \sum_{j=1}^G P(i,j) \right\}, |i-j| = n \quad (9)$$

3. Homogenitas (*Homogeneity*)

Homogenitas mengcitrakan keseragaman struktur grayscales citra. Persamaan homogenitas dapat ditulis sebagai berikut:

$$Homogeneity = \sum_{i,j=1}^N \frac{P(i,j)}{1 + |i-j|} \quad (10)$$

atau

$$Homogeneity = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{1}{1 + (-j)^2} P(i,j) \quad (11)$$

4. Korelasi (*Correlation*)

Korelasi menunjukkan ukuran ketergantungan linear derajat keabuan citra sehingga dapat memberikan petunjuk adanya struktur linear dalam citra. Persamaan korelasi dapat ditulis sebagai berikut:

$$Correlation = \sum_{i,j=1}^N \frac{(i - \mu_i)(j - \mu_j)P(i,j)}{\sigma_i \sigma_j} \quad (12)$$

atau

$$Correlation = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{\{i \times j\} \times P(i,j) \{\mu_x \times \mu_y\}}{\sigma_x \times \sigma_y} \quad (13)$$

Dengan keterangan:

μ_x = nilai rata-rata elemen kolom matrik $Pd_{\theta}(i,j)$

μ_y = nilai rata-rata elemen baris matrik $Pd_{\theta}(i,j)$

σ_x = standar deviasi elemen kolom matrik $Pd_{\theta}(i,j)$

σ_y = standar deviasi elemen baris matrik $Pd_{\theta}(i,j)$

2.1.9. *Regionprops*

Fungsi *regionprops* merupakan salah satu *tools* yang paling banyak digunakan pada Matlab terkait dengan pemrosesan citra morfologis. Secara umum fungsi ini mengukur satu set properti untuk setiap bagian (*region*) yang berlabel pada citra biner[39].

Berikut adalah sintaks yang sering digunakan untuk fungsi ini pada aplikasi Matlab untuk pengolahan cerita:

stats = *regionprops*(*BW*,*properties*)

stats = *regionprops*(*CC*,*properties*)

stats = *regionprops*(*L*,*properties*)

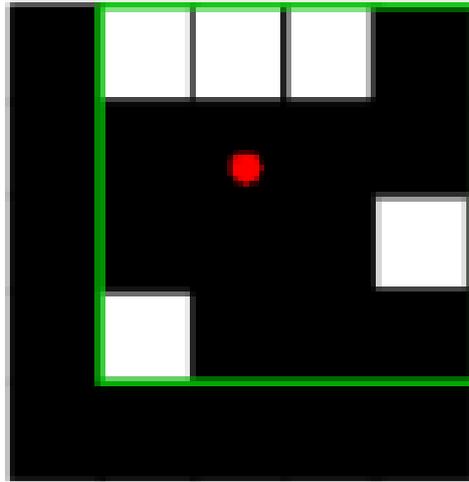
stats = *regionprops*(___,*L*,*properties*)

stats = *regionprops*(*output*,___)

stats = *regionprops*(*gpuarrayImg*,___)

Implementasi fungsi *regionprops* ini dapat dilakukan pada *region* yang bersebelahan dan tidak berurutan, dengan menerapkan berbagai properti seperti: *Area*, *BoundingBox*, *Centroid*, *ConvexArea*, *EquivDiameter*, *Extent*, *Extreme*, *FilledArea*, *Orientation*, *Solidity*, dan properti lainnya yang selalu mengembalikan pengaturan terstruktur untuk setiap objek yang ditemukan pada citra masing-masing.[39]

Pada pemrosesannya fungsi *regionprops* merepresentasikan sebuah objek sebagian *region* dengan pendekatan bentuk persegi panjang seperti pada Gambar 2.5 yang menunjukkan sebuah *region* dari dari kumpulan piksel berwarna putih yang direpresentasikan dengan pendekatan bentuk persegi panjang[40].



Sumber: [40]

Gambar 2.5 Representasi *regionprops* dengan pendekatan persegi panjang

Kontur suatu objek, selain menggunakan kode rantai untuk, juga dapat dideskripsikan menggunakan metode region properties dengan pendekatan bentuk elips[41], seperti pada Gambar 2.6 berikut:



Sumber: [41]

Gambar 2.6 Representasi *regionprops* dengan pendekatan elips

Pada penelitian ini menggunakan 5 properti regionprop yaitu *Area*, *Perimeter*, *Metric*, *Major Axis Length*, dan *Minor Axis Length*.

1. Area

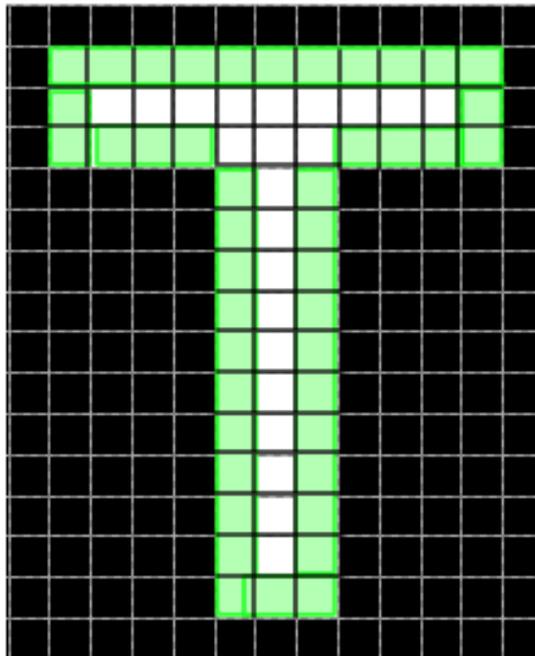
Fitur area menghasilkan nilai luas dari masing-masing objek pada citra. Persamaan area untuk menghitung nilai luas total dari semua objek yang ada, seperti pada persamaan berikut:

$$A = \sum_{i=1}^k a_i \quad (14)$$

Variabel A merepresentasikan luas total dari seluruh objek. Variabel k adalah jumlah dari objek yang ditemukan pada citra, a_i merepresentasikan luas objek ke i [37].

2. Perimeter

Perimeter merupakan element vektor p yang mengandung jumlah piksel di sekitar batas setiap wilayah pada citra, di mana p adalah jumlah wilayah. Gambar 2.7 menunjukkan piksel yang termasuk dalam perhitungan perimeter untuk objek ini. Daerah harus bersebelahan. Jika citra berisi daerah yang tidak jelas, perimeter mengembalikan hasil yang tidak terduga[37].



Sumber: [40]

Gambar 2.7 Representasi Perimeter

3. Metric

Metric merupakan sebuah besaran yang menunjukkan tingkat kebulatan bentuk suatu objek. Nilai metric = $4\pi \times \text{area} / (\text{perimeter})^2$. Nilai ini berkisar antara 0 hingga 1. Semakin bulat suatu objek, maka nilai metric-nya semakin mendekati 1[42].

4. Major Axis Length

Nilai major axis length adalah jarak terjauh antara centroid dengan koordinat pixel terluar dan hanya support pada bentuk citra dengan metrik 2 dimensi atau citra biner[41].

5. Minor Axis Length

Nilai minor axis length adalah jarak antara centroid dengan koordinat pixel terdekat dan hanya support pada bentuk citra dengan metrik 2 dimensi atau citra biner [41].

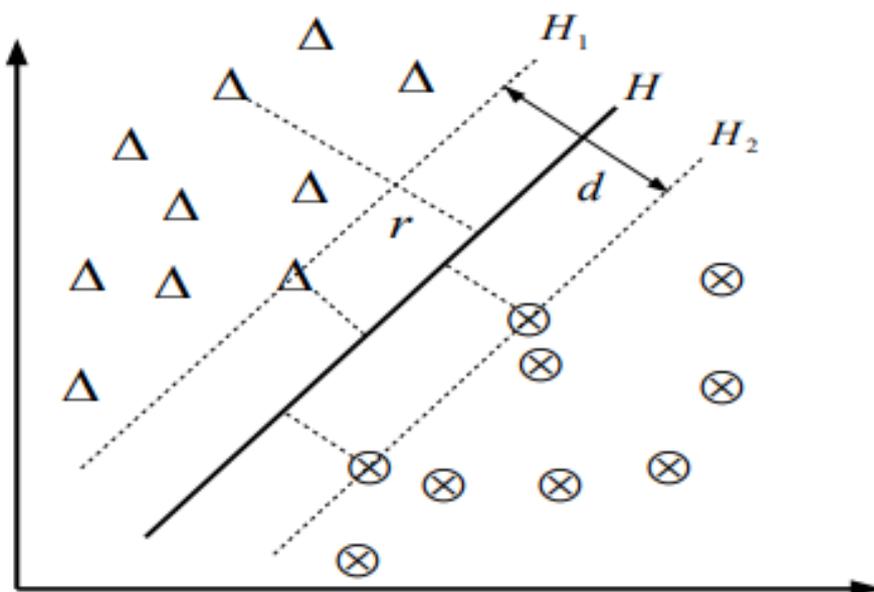
2.1.10. Multi-SVM

Support Vector Machines (SVM) pertama diusulkan oleh Vladimir Vapnik dalam bidang teori pembelajaran statistik dan minimalisasi risiko struktural, telah menunjukkan keberhasilan dalam berbagai klasifikasi dan masalah peramalan. SVM telah digunakan dalam banyak pengenalan pola dan masalah estimasi regresi dan telah diterapkan pada masalah estimasi ketergantungan, peramalan dan pembuatan mesin cerdas. SVM memiliki calon untuk menangkap ruang fitur yang sangat besar, karena prinsip generalisasi yang didasarkan pada Teori *Structural Risk Minimization* (SRM) yaitu, algoritma didasarkan pada batas risiko yang dijamin dari teori pembelajaran statistik[43].

Batas keputusan *Multi Class SVM* ditentukan langsung dari set data pelatihan dengan batas pemisah margin yang dapat dimaksimalkan dalam ruang fitur. SVM adalah *fringe hyperplane* maksimum yang terletak pada beberapa ruang dan mengklasifikasikan data yang dipisahkan oleh batas-batas non-linier yang dapat dibangun dengan menempatkan seperangkat *hyperplanes* yang memisahkan dua atau lebih kelas poin data. Setelah konstruksi *hyperplanes*, SVM menemukan batas

antara kelas input dan elemen input yang mendefinisikan batas. Dari serangkaian sampel pelatihan yang diberi label positif atau negatif, *hyperplane* margin maksimum membagi sampel pelatihan positif atau negatif, akibatnya jarak antara margin dan *hyperplane* dimaksimalkan. Jika tidak ada *hyperplanes* yang dapat membagi sampel positif atau negatif, SVM memilih *hyperplane* yang membelah sampel seketat mungkin, sambil tetap memaksimalkan jarak ke contoh split sederhana terdekat[44].

Gambar 2.8 menunjukkan *hyperplane* yang terpisah secara linear, dimana pada Gambar 2.8 di bawah dijelaskan ada dua kelompok titik data yang diwakili dengan simbol 'x' dan 'Δ'. Kemungkinan ada jumlah *hyperplane* yang tak terbatas seperti dijelaskan pada Gambar 2.8, hanya satu bidang hiper yang diwakili oleh garis padat yang secara optimal memisahkan titik sampel dan terletak di antara margin maksimal[44].



Sumber: [44]

Gambar 2.8 Sampel Dipisahkan Secara Linear dalam Hyperplane

Misal terdapat N training sampel seperti $\{(p_1, q_1), (p_2, q_2) \dots (p_N, q_N)\}$ dimana $p_i \in R^d$ dan $q_i \in \{1, -1\}$. Persamaan di bawah merepresentasikan persamaan *hyperplane* yang digunakan pada porsi data SVM.

$$W \cdot p + b = 0 \quad (15)$$

Dimana W adalah weight / berat, p adalah sampel training dan b adalah bias dari hyperplane. Margin antara dua kelas yang dimaksimalisasi untuk $|W|$ yang harus dimaksimalisasi dengan subjek pada kondisi tertentu.

$$q_i(W * p_i + b) \geq 1 \quad (16)$$

Optimasi masalah dapat didefinisikan sebagai:

$$\min_{w, b} \frac{1}{2} W^T W \text{ dengan mematuhi aturan } q_i(W * p_i + b) \geq 1, \text{ for } i = 1, 2, \dots, N$$

$$\text{Untuk meminimalisasi nilai } \frac{1}{2} W^T W, p_i \text{ dan } q_i \in \{1, -1\} \quad (17)$$

Dengan mengenalkan Multiplier Lagrange $\beta_1, \beta_2, \dots, \beta_N \geq 0$ untuk menyelesaikan permasalahan

$$L(W, b, \beta) = \frac{1}{2} W^T W - \sum_{i=1}^N \beta_i q_i (W * p_i + b) \sum_{i=1}^N \beta_i \quad (18)$$

Maka, masalahnya menjadi $\max L(\beta) = \sum_{i=1}^N \beta_i - \frac{1}{2} \sum_{i,j=1}^N \beta_i \beta_j q_i q_j p_i \cdot p_j$ dengan subjek $\sum_{i=1}^N \beta_i q_i = 0, \beta_i \geq 0$

Sekarang, jika β_i adalah solusi optimal, nilai-nilai bias dan berat optimal yang sesuai dapat diperbarui sebagai:

$$W * = \sum_{i=1}^N q_i \beta_i * p_i \quad (19)$$

$$b * = -\frac{1}{2} W * [p_m + p_n] \quad (20)$$

Dimana p_m, p_n adalah support vektor.

2.1.11. Neural Network

Menurut Siang[45], *Artificial Neural Network (ANN)* yang lebih populer dengan istilah *Neural Network (NN)* pertama kali diperkenalkan oleh McCulloch dan Pitts pada tahun 1943. *Neural Network* dikembangkan sebagai model matematika yang menyerupai pola pikir manusia atau jaringan syaraf makhluk hidup, dengan asumsi bahwa:

1. Proses informasi terjadi pada banyak elemen sederhana yang disebut neuron.
2. Sinyal yang melewati antar neuron menggunakan hubungan tertentu.
3. Setiap penghubung antar *neuron* mempunyai bobot (*weight*) yang bersesuaian dengan mengalikan sinyal yang dikirimkan. Bobot ini dapat memperkuat maupun memperlemah sinyal.
4. Setiap *neuron* menggunakan fungsi aktivasi terhadap input (jumlah sinyal input yang terboboti) untuk menentukan sinyal output.

Seperti halnya otak manusia jaringan syaraf juga terdiri dari beberapa neuron dan ada hubungan antara neuron-neuron tersebut. Neuron-neuron tersebut akan mentransformasikan informasi yang diterima melalui sambungan keluarnya menuju ke neuron-neuron yang lain. Pada jaringan syaraf, hubungan ini dikenal dengan nama bobot. Dalam memproses informasi, jaringan syaraf manusia memiliki 3 elemen dasar sebagai berikut:

1. Himpunan Penghubung, merupakan himpunan unit-unit yang dihubungkan dengan satu jalur koneksi. Jalur-jalur tersebut memiliki bobot yang berbeda. Bobot yang bernilai positif akan memperkuat sinyal sedangkan bobot yang bernilai negatif akan memperlemah sinyal. Jumlah, struktur dan pola hubungan antar unit-unit tersebut akan menentukan arsitektur jaringan yang terbentuk.
2. Fungsi Penjumlah, merupakan suatu unit yang akan menjumlahkan input-input sinyal yang sudah dikalikan dengan bobot masing-masing.
3. Fungsi Aktivasi, merupakan sebuah fungsi transfer yang berguna untuk menyesuaikan output yang dihasilkan oleh sistem jaringan syaraf sehingga sesuai dengan target. Dengan demikian jaringan menjadi lebih powerfull dalam mengenali pola.

Neural Network / Jaringan Saraf Tiruan (JST) adalah paradigma pengolahan informasi yang terinspirasi oleh sistem saraf secara biologis, seperti proses informasi pada otak manusia. Elemen kunci dari paradigma ini adalah struktur dari sistem pengolahan informasi yang terdiri dari sejumlah besar elemen pemrosesan yang saling berhubungan (*neuron*), bekerja serentak untuk menyelesaikan masalah tertentu. Cara kerja JST seperti cara kerja manusia, yaitu belajar melalui contoh.

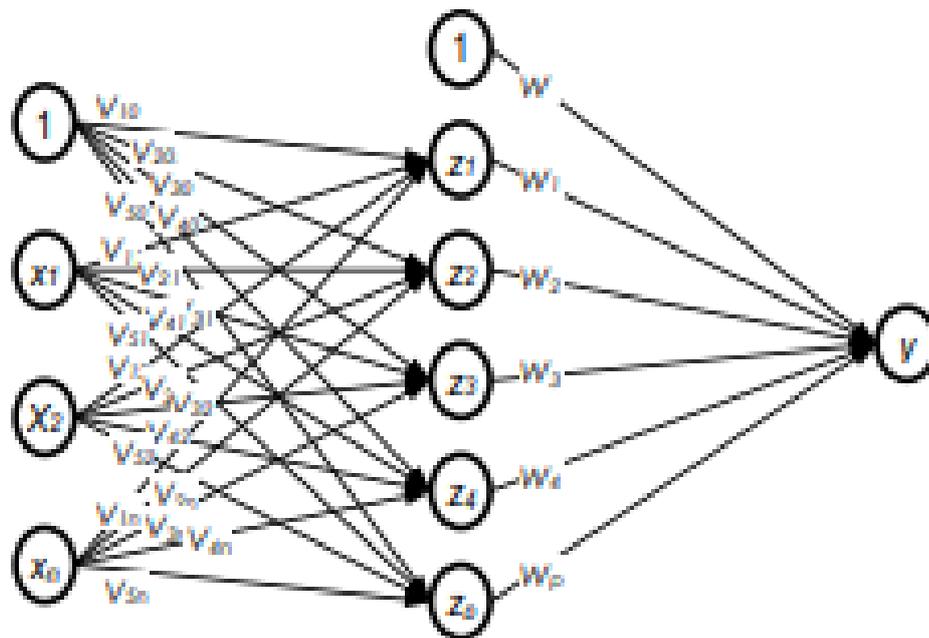
Lapisan-lapisan penyusun JST dibagi menjadi 3, yaitu lapisan input (input layer), lapisan tersembunyi (*hidden layer*), dan lapisan output (*ouput layer*)[46].

Beberapa hasil penelitian menyimpulkan bahwa kekuatan utama dalam metode *Artificial Neural Network* terletak pada kemampuannya untuk mengetahui hubungan linier yang melekat pada data, sedangkan model linier menggambarkan hubungan linier antara pengamatan saat ini dan waktu yang akan datang. *Artificial Neural Network* menggambarkan hubungan non linear antara keduanya[47]. Seperti digambarkan pada persamaan berikut:

$$y_t = f(y_{t-1}, y_{t-2}, \dots, y_{t-p}) + \varepsilon_t \quad (21)$$

Dimana, $f(y_{t-1}, y_{t-2}, \dots, y_{t-p})$ adalah fungsi non linear yang memetakan serangkaian pengamatan non linear masa lalu dengan hasil berikutnya. Fungsi ini adalah model neural network. Komponen terakhir persamaan yaitu ε_t adalah kesalahan yang sebagai menjadi variabel acak dengan rata-rata 0 dan varians σ^2 .

Pada peramalan data runtun waktu digunakan metode propagasi balik (*backpropagation*) yang merupakan metode pelatihan terawasi yang diterapkan pada *Artificial Neural Network*. Metode ini memiliki satu atau lebih lapisan tersembunyi (*hidden layer*). Gambar 2.9 menunjukkan contoh arsitektur *Artificial Neural Network* 3-layer. Lapisan masukan mempunyai n buah *node*, yaitu: $X_1, X_2, X_3, \dots, X_n$. Lapisan tersembunyi mempunyai p buah *node* yaitu $Z_1, Z_2, Z_3, \dots, Z_p$. Lapisan luaran (*output layer*) memiliki 1 buah *node* yaitu Y . Bobot dari lapisan masukan ke lapisan tersembunyi dinyatakan dengan V_{pn} dengan p adalah node ke- p pada lapisan tersembunyi dan n adalah *node* ke n pada lapisan masukan, sedangkan V_{po} adalah bias yang masuk node ke- p pada lapisan tersembunyi. Bobot dari lapisan tersembunyi ke lapisan luaran dinyatakan dengan W_{mp} dengan m adalah node ke- m pada lapisan luaran dan p adalah *node* ke- p pada lapisan tersembunyi, sedangkan V_{mo} adalah bias yang masuk *node* ke- m pada lapisan luaran. Pada *Arsitektur Artificial Neural Network multilayer*, salah satu permasalahan yang dijumpai adalah menentukan jumlah neuron pada lapisan tersembunyi.



Sumber: [47]

Gambar 2.9 Arsitektur Neural Network

2.1.12. Pengukuran *Confusion Matrix*

Confusion matrix memberikan keputusan yang diperoleh dalam training dan testing, *confusion matrix* memberikan penilaian performance klasifikasi berdasarkan objek dengan benar atau salah. *Confusion matrix* berisi informasi aktual (*actual*) dan informasi terprediksi (*predicted*) pada sistem klasifikasi. *Confusion Matrix* merupakan sebuah metode untuk evaluasi yang menggunakan tabel *matrix* seperti pada Tabel 2.2. Dapat kita lihat dari Tabel 2.2 bahwa jika dataset terdiri dari dua kelas, kelas yang satu dianggap sebagai positif dan yang lainnya negatif. Evaluasi dengan *confusion matrix* menghasilkan nilai *accuracy*, *precision*, dan *recall*[48].

Tabel 2.2 *Confusion Matrix*

Correct Classification	Classified as	
	+	-
+	True_positive	False_positive
-	False_positive	True_positive

Sumber: [48]

True Positive (TP): Mengacu pada tupel positive yang benar diberi label oleh classifier.

True Negative (TN): Mengacu pada tupel negative yang benar kemudian diberi label oleh classifier.

False Positive (FP): Tupel negative yang salah diberi label sebagai positive.

False Negative (FN) : Tupel positive yang salah diberi label negative

2.2. Tinjauan Studi

Terdapat beberapa penelitian mengenai citra beras, baik itu penggunaan metode ekstraksi fitur dan algoritma klasifikasi yang sama dan menjadi acuan dalam penelitian ini. Berikut adalah beberapa penelitian yang menjadi acuan pada penelitian ini:

1. Fabiyi dan kawan-kawan[49] melakukan penelitian tentang klasifikasi varietas pada butir beras untuk menilai kualitas suatu beras dengan RGB dan *Hyperspectral Image*. Hasil percobaan pada penelitian ini menunjukkan bahwa hasil klasifikasi yang sangat baik dan penghapusan spesies tidak murni dari sampel benih padi dapat dicapai dengan mengambil keuntungan dari fitur spasial dari citra resolusi spasial tinggi dan menggabungkannya dengan fitur spektral dari *hyperspectral data cubes*. Kinerja suboptimal yang dilaporkan untuk beberapa kategori dikaitkan dengan penggunaan sampel dengan sejumlah besar spesies dan kesamaan diantara spesies. Hasil dari penelitian ini mengevaluasi performa dengan teknik *NIR spectral data*.
2. Penelitian yang dilakukan oleh T. Gayathri Devi dan kawan-kawan[13] pada citra daun padi untuk mengetahui kerusakan yang dialami oleh padi tersebut menggunakan segmentasi *K-Means Clustering* dengan membaginya pada tiga *cluster*. Setelah hasil segmentasi muncul dengan masing-masing *cluster*-nya, maka dipilihlah *cluster* 1 dengan hasil segmentasi yang cukup baik karena dapat menunjukkan antara objek yang akan diteliti yaitu *spot* yang ada pada daun tersebut dengan latar belakang atau objek lain yang ada pada citra yang tidak menjadi bagian dari objek penelitian. Sebelum dilakukan segmentasi, citra terlebih dahulu dilakukan

pre-processing dengan *Median Filter* untuk menghapus *noise* dari citra. *Media Filter* terbukti dapat menghilangkan *noise* terutama *salt noise* dan *pepper noise*. Metode ekstraksi fitur yang dipilih adalah DWT, SIFT, dan GLCM. DWT tidak bersifat *shift-invariant*. Karena DWT menurunkan sampel, pergeseran dalam sinyal input tidak memanifestasikan dirinya sebagai pergeseran ekuivalen sederhana dalam koefisien DWT di semua tingkatan. Pergeseran sederhana pada sinyal dapat menyebabkan penyalarsan energi sinyal secara signifikan dalam koefisien DWT berdasarkan skala. Jadi setelah skala invarian mentransformasikannya diperkuat menjadi DWT. GLCM diterapkan untuk semua citra uji dengan tingkat komponen yang rendah. Untuk algoritma yang digunakan sebagai penentu kerusakan dg ekstraksi fitur tersebut adalah KNN, ANN, Naïve Bayesian dan Multiclass SVM classifier. Hasil akurasi tertinggi didapat dari Multiclass SVM Classifier dengan besar 98,63%.

3. David Ricardo dan Gasim[7] melakukan penelitian pada citra beras lokal, yaitu beras pandan wangi, beras Jawa barat, beras Jawa Timur dan beras luar negeri yaitu beras Thailand dan beras Vietnam. Akuisisi dalam penelitian ini menggunakan kamera *handphone* beresolusi 5MP (aperture f/2.2, sensor size 1/3”), 8 MP (aperture f/2.7), 12MP (aperture f/1.8, sensor size 1/2.8”), 14MP (aperture f/2.8 - 5.9, sensor size 1/2.3”), dan 16MP (aperture f/1.7, sensor size 1/2.8”) pada citra butir beras tersebut sehingga menghasilkan total 125 citra dengan pembagian 75 buah data citra latih dan 50 buah data citra uji. Grayscale dan Thresholding dipilih untuk menjadi metode dalam tahan pra-pemrosesan citra dan menghilangkan informasi yang kurang penting untuk dilakukan pengujian sehingga hanyafokus pada citra beras itu sendiri. Ekstraksi ciri pada penelitian ini menggunakan 4 properti dari GLCM yaitu *contrast*, *correlation*, *energy* dan *homogeneity*. Neural Network merupakan algoritma yang digunakan pada penelitian ini untuk menentukan jenis dari cira beras. Hasil akhir dari penelitian ini menunjukkan bahwa citra dengan pengambilan/akuisisi menggunakan kamera resolusi 12 MP memberikan hasil terbaik diantara citra lainnya dengan hasil akurasi total hasil perhitungan rata-rata yaitu sebesar 82%.

4. Arissa dan Ristu[50] melakukan pengumpulan data untuk diakuisisi dari gudang beras di Kecamatan Gemolong, Sragen. Jenis beras yang dipilih yaitu IR64 dari tingkat kualitas yang baik sampai yang buruk dengan total data sebanyak 30 citra. Akuisisi dilakukan dengan menggunakan kamera *handphone* resolusi 8 *megapixel* pada mode manual. Setelah citra diakuisisi, lalu dilakukan segmentasi dengan cara mengubahnya pada bentuk biner menggunakan *threshold*. Lalu, citra dilakukan penghitungan jumlah butir beras dengan cara memberi label pada setiap koordinat objek. Langkah selanjutnya adalah menghitung nilai putih beras dengan menanalaisis nilai *Hue*, *Saturation*, dan *Value* setiap objek sesuai dengan koordinat masing-masing. Jika nilai *Hue* diantara 0.2 hingga 0.7, nilai *Saturation* diantara 0.01 hingga 0.3, dan nilai *Value* diantara 0.55 hingga 0.9, maka objek diberi label “putih”, jika tidak maka diberi label “tidak”. Setelah diketahui nilai putih, selanjutnya dicari nilai bersih beras, dengan ketentuan jika nilai *saturation* < 0.4 dan nilai *Value* > 0.55 , maka objek diberi label “bersih”, jika tidak maka diberi label “tidak”. Langkah terakhir sebelum identifikasi adalah mencari nilai utuh beras dengan ketentuan jika luas $\geq 60\%$ dari standar, maka beras diberi label “ya”, jika tidak maka diberi label “tidak”. Algoritma ID3 digunakan untuk melakukan identifikasi. Hasil dari penelitian ini menunjukkan akurasi yang tinggi yaitu 96,67% yang didaat dengan metode *k-fold cross validation k=5*.
5. Thae Nu Wah dan kawan-kawan[51] melakukan penelitian pada citra beras Myanmar dengan jenis *paw-san rice*. Akuisisi pada penelitian ini menggunakan *flatbed scanner* dengan hasil resolusi 200 dpi. Pra-pemrosesan citra dilakukan dengan mengubahnya dari citra RGB ke citra *grayscale*, mengurangi ukuran citra dan melakukan *cropping* pada citra sesuai dengan yang dibutuhkan. Metode segmentasi pada penelitian ini menggunakan *threshold* dan menghapus *noise* dengan menerapkan operasi morfologi *bwareopen*. K Nearest Neighbor (KNN) digunakan sebagai algoritma klasifikasi menentukan kualitas suatu beras dengan fitur morfologi yaitu menghitung luar area butir citra beras. Hasil akurasi pada

penelitian ini menunjukkan pendeteksian yang cukup tinggi yaitu 100% untuk kelas A, 93% untuk kelas B, dan 83% untuk kelas C.

6. Kolkure dan Saikh[52] melakukan penelitian pada citra beras India dengan menggunakan kamera digital (Sony). Penelitian ini fokus pada pengujian kualitas suatu beras dengan pertama-tama melakukan tahap pra-pemrosesan citra. Pada tahap ini, citra di *resize* dan dilakukan perbaikan citra dengan menambah *contrast* dan mengurangi *noise* yang ada pada citra. Tahap segmentasi pada penelitian ini menggunakan *threshold*. Setelah dilakukan segmentasi, citra dicari nilai fitur menggunakan fitur morfologi yaitu *Area*, *Major Axis Length*, *Minor Axis Length*, dan *Aspect Ratio*. Neural Network digunakan sebagai algoritma untuk identifikasi hasil akhir dari kualitas citra beras tersebut.

Pada Tabel 2.3 dijelaskan mengenai kelebihan dan perbedaan antara penelitian sebelumnya dengan penelitian ini:

Tabel 2.3 Penelitian Sebelumnya

Judul Penelitian	Tahun	Quartile / Akreditasi	Kelebihan	Perbedaan
Varietal Classification of Rice Seeds Using RGB and Hyperspectral Images	2020	Q1 H index = 86	Ekstraksi fitur mengambil informasi spectral dari citra HIS dan RGB, klasifikasi menggunakan output fitur LDA	Hanya meneliti pada jenis beras Myanmar dengan jumlah citra 90, menggunakan dataset private.
Image Processing based rice plant leaves diseases in Thanjavur, Tamilnadu	2018	Q2 H index 41	Ekstraksi fitur yang digunakan menggunakan metode hybrid SIFT, DWT dan GLCM sehingga	Penelitian dilakukan pada citra daun padi, dataset yang digunakan

			<p>menghasilkan 13 fitur yang telah difilter.</p> <p>Klasifikasi menggunakan algoritma Multi-SVM yang dibandingkan dengan KNN, ANN dan Naïve Bayesian.</p>	merupakan data private.
Perbandingan Akurasi Pengenalan Jenis Beras dengan Algoritma Propagasi Balik pada Beberapa Resolusi Kamera	2019	Sinta 2	<p>Melakukan segmentasi dengan thresholding dan ekstraksi fitur menggunakan metode GLCM dengan algoritma ANN pada citra beras lokal yang diakuisisi dengan berbagai ukuran megapixel.</p>	<p>Ekstraksi fitur hanya menggunakan metode GLCM dengan 4 fitur dengan dataset yang digunakan yaitu dataset private.</p>
Identifikasi Kualitas Beras dengan Citra Digital	2015	Sinta 2	<p>Metode yang digunakan dalam identifikasi mengikuti aturan Decision Tree ID3. Ekstraksi fitur mengambil dari nilai HSV.</p>	<p>Hanya mengidentifikasi beras dari jumlah bulir dan nilai putih dengan mengambil nilai HSV, dataset menggunakan</p>

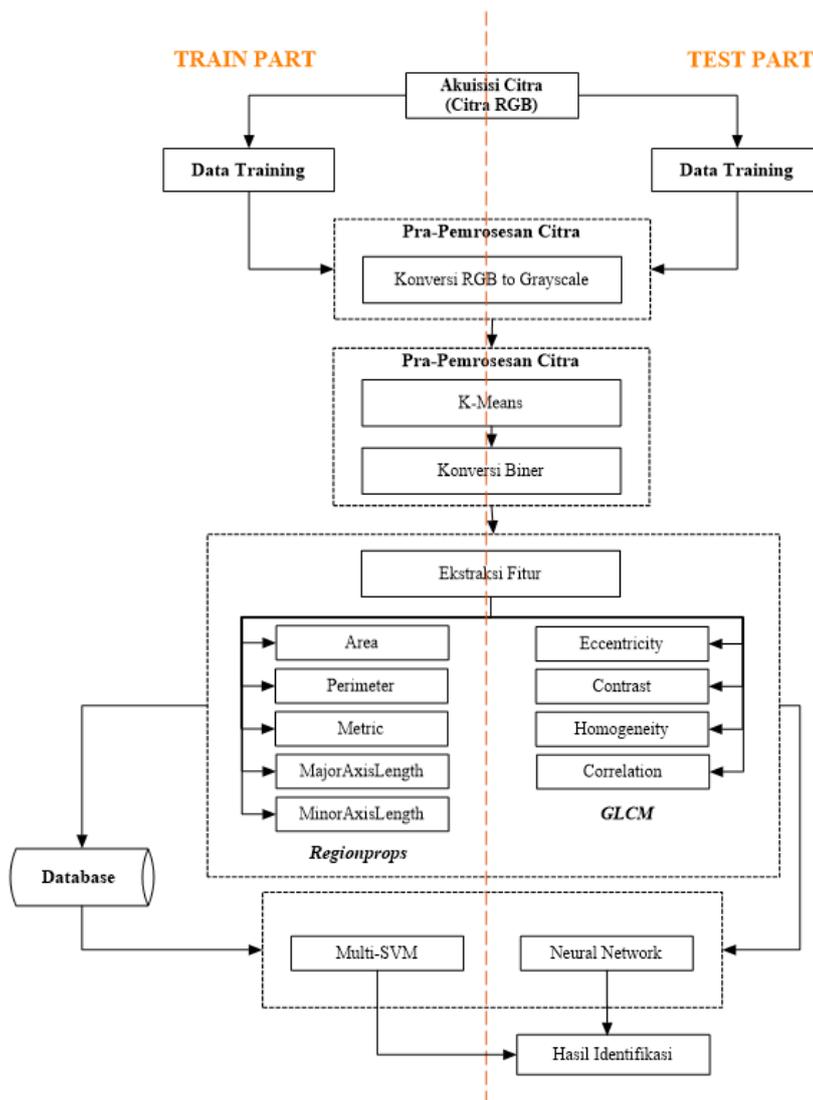
				data private citra beras lokal.
Analysis on Feature Extraction and Classification of Rice Kernels for Myanmar Rice Using Image Processing Techniques	2018		Algoritma yang digunakan pada klasifikasi adalah K-NN dengan segmentasi threshold menggunakan otsu. Ekstraksi fitur mengkalkulasikan area biji beras berdasarkan jumlah pixel masing-masing biji.	Hanya menggunakan satu fitur dan satu jenis beras, dengan dataset private yang diambil menggunakan flatbed scanner.
Identification and Quality Testing Of Rice Grains Using Image Processing And Neural network	2016		Algoritma pada klasifikasi menggunakan Neural Network pada satu jenis beras dengan segmentasi threshold. Metode ekstraksi fitur yang digunakan adalah fitur morfologi terdiri dari regionprop.	Hanya meneliti satu jenis beras saja, dataset menggunakan data private dengan akuisisi citra menggunakan kamera digital.

BAB III

METODOLOGI PENELITIAN

3.1. Perancangan Penelitian

Penelitian memiliki fungsi dalam mencari penjelasan dan jawaban terhadap permasalahan serta memberikan alternatif bagi kemungkinan yang dapat digunakan untuk pemecahan masalah[53]. Dalam melakukan penelitian diperlukan model penelitian untuk menghasilkan pengetahuan baru yang ingin dicapai. Berikut pada Gambar 3.1 adalah model penelitian pada penelitian ini:



Sumber: [54]

Gambar 3.1 Model Penelitian

3.2. Objek Penelitian

Objek pada penelitian ini adalah citra butir beras impor Indonesia yang diakuisisi menggunakan flatbed scanner dengan tiga varietas yaitu beras basmati, jasmine dan japonica.

3.3. Pengumpulan Data

Pengumpulan data pada penelitian ini dilakukan dengan mengakuisisi citra 3 jenis beras impor dari 3 negara yang terjual luas di pasar lokal Indonesia, diambil dengan menggunakan metode *flatbed scanning* menghasilkan 90 citra digital yang dilakukan penelitian sesuai dengan model penelitian.



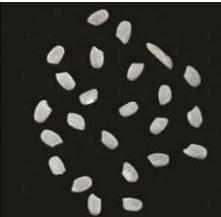
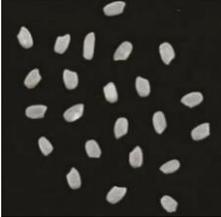
Gambar 3.2 (a) beras jasmine, (b) beras japonica, (c) beras basmati

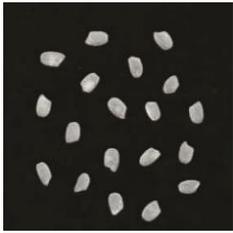
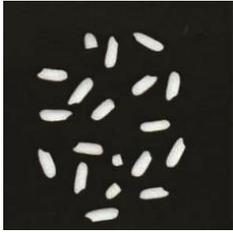
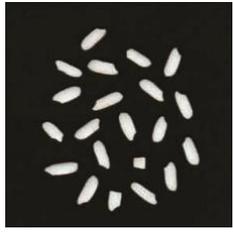
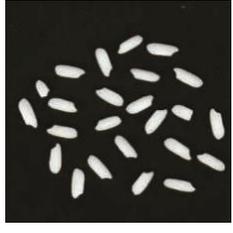
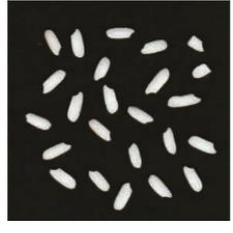
Pada Gambar 3.2 dapat kita lihat beras hasil pengumpulan data yang akan dilakukan akuisisi untuk menjadi citra digital yang terdiri dari beras jasmine (Gambar 3.2a), beras japonica (Gambar 3.2b) dan beras basmati (Gambar 3.2.c).

3.4. Pengolahan Data Awal

Pengolahan data awal pada penelitian ini adalah melakukan akuisisi butir beras menjadi citra butir beras digital dan memberikan penamaan pada masing-masing citra untuk menjadi dataset pada penelitian tentang identifikasi beras. Berikut pada Tabel 3.1 adalah 90 total dataset citra terdiri dari 3 varietas masing-masing 30 citra yang digunakan pada penelitian ini:

Tabel 3.1 Dataset Butir Beras

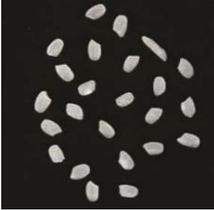
No	Nama File	Citra
1	basmati1	
2	basmati2	
3	basmati3	
...
30	basmati30	
31	japonica1	
32	japonica2	

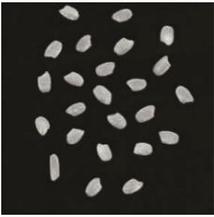
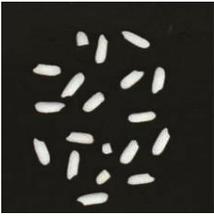
33	japonica3	
...
60	japonica30	
61	jasmine1	
62	jasmine2	
63	jasmine3	
...
90	jasmine30	

Sumber: Hasil Penelitian (2020)

Setelah terkumpul 90 total citra seperti yang ditampilkan pada Tabel 3.1, maka citra tersebut dibagi dua menjadi data training dan data testing. Dalam pembagain data training dan testing semakin banyak data yang digunakan maka estimasi akurasi dimungkinkan semakin tinggi[55]. Berdasarkan penelitian sebelumnya[13][56][57] dalam pembagian dataset citra untuk dilakukan pemrosesan pada citra tersebut, maka pada penelitian ini menggunakan 70% untuk data training dan 30% data testing dari keseluruhan total citra dan pembagian varietas yang sama. Berikut adalah sampel dari pembagian data training dan testing yang ditampilkan pada Tabel 3.2:

Tabel 3.2 Data Training Butir Beras

No	Nama File	Citra
1	basmati1	
...
21	basmati21	
22	japonica1	
...

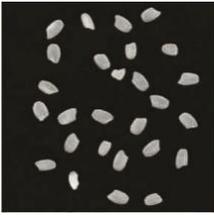
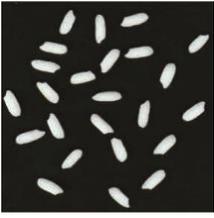
42	japonica21	
43	jasmine1	
...
63	jasmine21	

Sumber: Hasil Penelitian (2020)

Pada tabel 3.2 dijelaskan bahwa data training yang diambil pada penelitian ini adalah 70% dari total keseluruhan 90 citra yaitu 63 dengan pembagian jumlah varietas masing-masing 21 dengan mengambil citra urutan 1-21. Selanjutnya jumlah data testing pada penelitian ini adalah sebagai berikut:

Tabel 3.3 Data Testing Butir Beras

No	Nama File	Citra
1	basmati22	
...

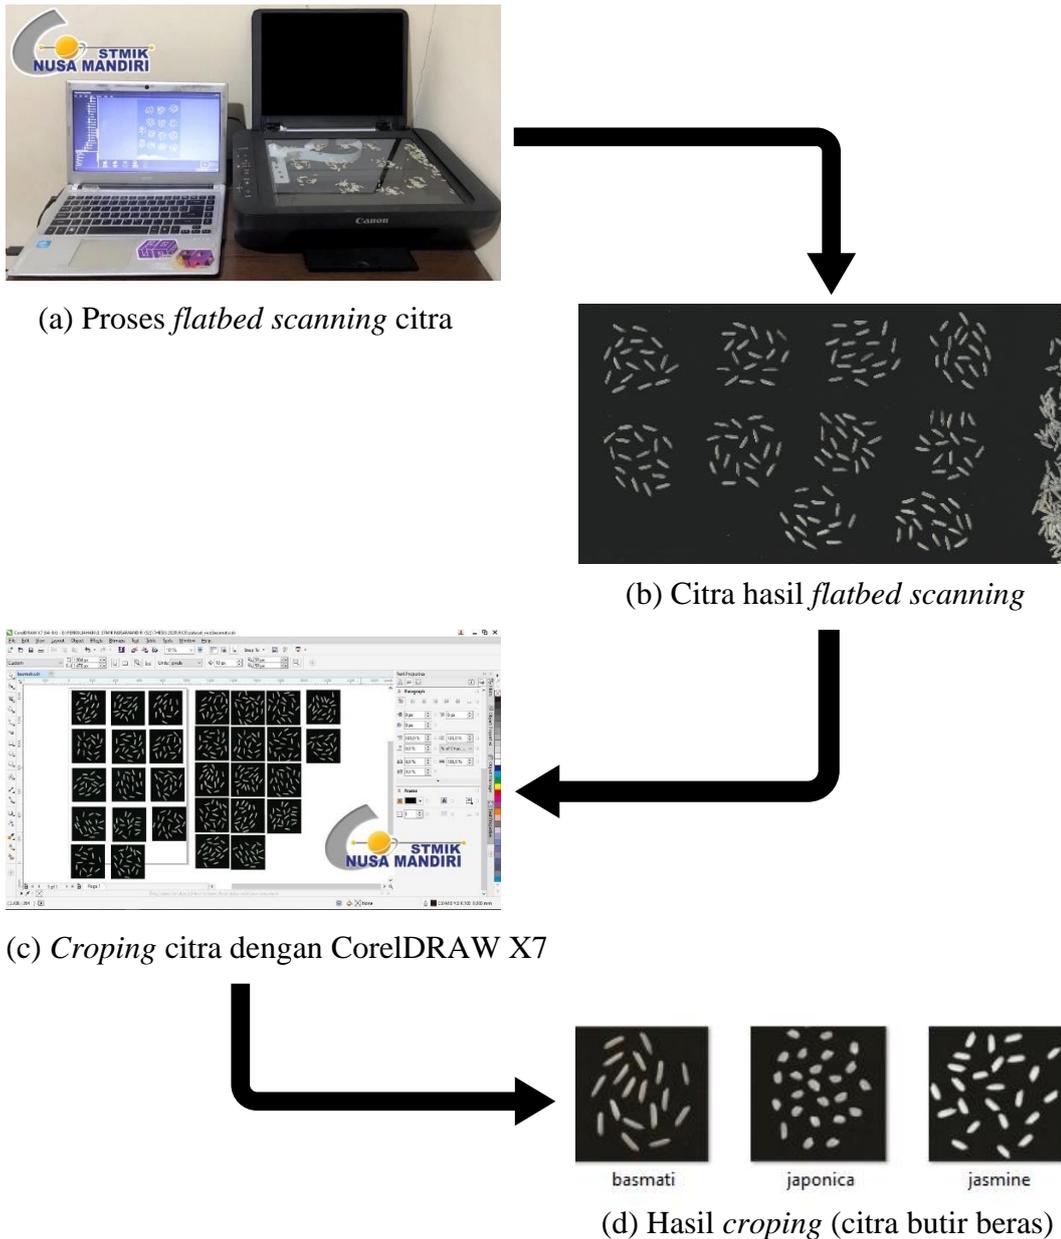
9	basmati30	
10	japonica22	
...
18	japonica30	
19	jasmine22	
...
27	jasmine30	

Sumber: Hasil Penelitian (2020)

Pada Tabel 3.3 dijelaskan bahwa data testing yang digunakan pada penelitian ini merupakan 30% dari jumlah total keseluruhan citra yaitu 27 citra dengan masing-masing 7 citra dari setiap varietas. Untuk citra beras jenis basmati digunakan mulai dari nomor urut pada penamaan 22 sampai 30, citra beras jenis jasmine mulai dari nomor urut citra pada penamaan 22 sampai 30 dan citra beras jenis japonica mulai dari nomor urut pada penamaan 22 sampai 30.

3.4.1. Akuisisi Citra

Tahap akuisisi citra pada penelitian ini merupakan pengambilan objek penelitian untuk menjadi bahan dataset dengan mengubahnya menjadi bentuk digital menggunakan metode *flatbed scanning*. Berikut pada Gambar 3.3 adalah penjelasan akuisisi citra yang dilakukan:



Sumber: Hasil Penelitian (2020)

Gambar 3.3 Akuisisi Citra

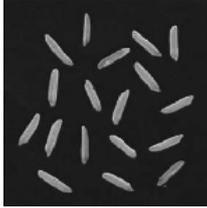
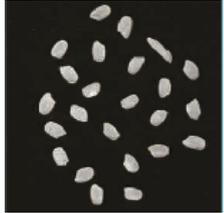
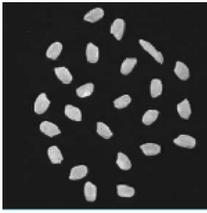
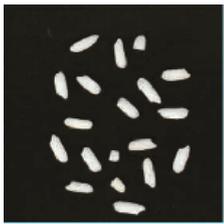
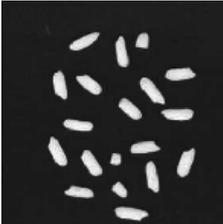
Dilihat dari Gambar 3.3, tahap pertama pada proses akuisisi citra ini adalah melakukan proses akuisisi awal yaitu digitalisasi citra atau mengambil objek versi digital dalam format citra menggunakan *flatbed scanner* model Canon MG2570S dengan resolusi 600 x 1200 dpi maksimum *scan* 216 x 297 mm (A4) pada background warna hitam solid untuk menghindari distraksi warna pada objek penelitian dan objek lain atau *noise* (Gambar 3.3a). Objek diletakan pada piringan scanner dikelompokkan beberapa butir secara acak dan berjarak untuk menghindari *overlapping image* yaitu citra bertumpuk yang dapat menghambat pemrosesan karena harus menambah metode lain untuk memisahkan citra tersebut. Sehingga menghasilkan citra beras digital awal (Gambar 3.3b).

Setelah dilakukan *scanning* pada objek sehingga menjadi citra digital, lalu citra dilakukan *cropping* atau pemotongan citra menggunakan aplikasi *CorelDRAW Graphic Suit X7* dengan besar piksel yang sama yaitu 286 x 286 dan dilakukan pengelompokan masing-masing serta diberi penamaan sesuai urutan dan varietas jenis beras (Gambar 3.3c). Selanjutnya citra disimpan dengan format PNG (*Portable Network Graphics*) seperti pada Gambar 3.3d.

3.4.2. *Image Processing*

Pada tahap pemrosesan citra atau *image processing* ini, citra dilakukan pemrosesan awal setelah berhasil diakuisisi dan dilakukan *cropping*. Pemrosesan awal ini adalah tahap prapemrosesan citra dengan melakukan konversi citra menjadi citra skala abu-abu (*grayscale*). Karena citra hasil akuisisi dengan format PNG ini berskala RGB dengan 3 lapisan warna yaitu merah (*red*), hijau (*green*) dan biru (*blue*). Tujuan pengubahan atau konversi bentuk citra dari citra awal RGB menjadi *grayscale* ini adalah untuk menyederhanakan lapisan matrik dari citra itu sendiri. RGB memiliki 3 lapisan matrik dan memerlukan metode tersendiri untuk memprosesnya, diubah menjadi *grayscale* dengan 1 lapisan matrik. Pada penelitian ini *grayscale* lebih diperlukan karena pada tahap segmentasi menggunakan *K-Means Clustering* lapisan matriks yang digunakan adalah 1 lapisan matrik dari citra *grayscale*. Berikut pada Tabel 3.4 hasil konversi citra butir beras dari citra RGB menjadi citra *grayscale*:

Tabel 3.4 Konversi Citra RGB ke *Grayscale*

Nama File	Citra RGB	Citra <i>Grayscale</i>
basmati1		
japonica1		
jasmine1		

Sumber: hasil penelitian (2020)

Berikut adalah matrik hasil konversi *grayscale* citra basmati1 yang ditampilkan pada Gambar 3.4 dengan menggunakan fungsi MATLAB uint8:

```

Command Window
>> a=imread('E:\THESIS\citra_latih70\basmati1.png','png');
>> c=rgb2gray(a);
>> asci=uint8(c)

asci =

Columns 1 through 28

28 24 32 19 26 27 27 27 27 27 27 27 27 27 25 25 25 25 25 25 25 25 24 24 25 25 25 25
34 28 37 24 30 31 32 32 32 32 32 32 31 31 31 31 31 31 31 31 31 31 31 32 32 32 32 32 32
27 22 31 17 25 26 26 26 26 26 26 26 26 26 26 26 26 26 26 26 26 26 28 28 28 28 28 28
28 22 32 18 26 26 26 27 27 27 27 26 26 28 28 28 28 28 28 28 28 28 28 28 29 29 29 29 29
34 29 39 25 33 33 34 34 34 34 34 34 33 32 32 32 32 32 32 32 32 32 32 32 32 32 33 33
30 26 36 21 30 31 31 31 31 31 31 31 31 25 25 25 25 25 25 25 25 25 25 25 25 25 25 25
29 24 34 22 31 29 29 29 29 29 29 29 29 28 28 28 28 28 28 28 28 28 28 28 28 27 27 27
29 24 34 22 31 29 29 29 29 29 29 29 29 28 28 28 28 28 28 28 28 28 28 28 28 28 27 27
29 24 34 22 31 29 29 29 29 29 29 29 29 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28
29 24 34 22 31 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28
29 24 34 22 31 27 27 27 27 27 27 27 27 28 28 28 28 28 28 28 28 28 28 28 28 28 28 28
29 24 34 22 31 26 26 26 26 26 26 26 26 26 26 28 28 28 28 28 28 28 28 28 28 28 28 28 29
29 24 34 22 31 26 26 26 26 26 26 26 26 26 26 28 28 28 28 28 28 28 28 28 28 28 28 28 29
29 24 34 22 31 26 26 26 26 26 26 26 26 26 26 28 28 28 28 28 28 28 28 28 28 28 28 29 29
30 25 34 23 33 26 26 27 28 29 29 30 31 28 28 28 28 28 28 28 28 28 28 28 28 28 27 27
31 25 34 23 33 27 27 28 28 29 29 29 29 28 28 28 28 28 28 28 28 28 28 28 28 28 27 27
32 25 34 23 34 29 29 29 29 28 28 27 27 28 28 28 28 28 28 28 28 28 28 28 28 28 28 27 27
32 26 35 23 34 31 30 29 28 28 27 26 25 28 28 28 28 28 28 28 28 28 28 28 28 28 27 27

```

Sumber: hasil penelitian (2020)

Gambar 3.4 Matrix Grayscale Citra basmati1

Selanjutnya adalah *layout* matrik hasil konversi *grayscale* citra japonical yang ditampilkan pada Gambar 3.5 dengan menggunakan fungsi MATLAB `uint8`:

```

Command Window
>> c=imread('E:\THESIS\citra_latih70\japonical.png','png');
>> x=rgb2gray(c);
>> asci=uint8(x)

asci =

Columns 1 through 28

    24    21    34    19    27    25    25    25    25    25    25    25    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23
    29    27    39    24    32    30    30    30    30    30    30    30    30    29    29    29    29    29    29    29    28    28    28    28    28    28    28    28
    22    20    32    18    25    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23    23
    23    21    33    18    26    23    23    23    23    23    23    23    23    24    24    24    24    24    24    24    24    24    24    24    24    24    24    24
    30    27    40    24    32    30    30    30    30    30    30    30    30    30    30    30    30    30    30    30    30    28    28    28    28    28    28    28    28
    26    24    35    21    29    26    26    26    26    26    26    26    26    25    25    25    25    25    25    25    25    25    25    25    25    25    25    25
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    28    25    33    17    30    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    29    23    31    17    32    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    29    23    31    17    32    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26    26
    
```

Sumber: hasil penelitian (2020)

Gambar 3.5 Matrix Grayscale Citra japonical1

Pada Gambar 3.6 ditampilkan juga matrik hasil konversi *grayscale* citra jasmine1 dengan menggunakan fungsi MATLAB `uint8`:

```

Command Window
>> c=imread('E:\THESIS\citra_latih70\jasmine1.png','png');
>> x=rgb2gray(c);
>> asci=uint8(x)

asci =

Columns 1 through 28

    25    30    33    31    32    33    32    32    32    32    32    32    32    31    31    32    32    33    33    34    34    33    33    33    33    33    33    33
    16    22    25    23    24    24    21    21    21    21    21    21    21    22    22    22    22    23    23    23    23    23    23    23    23    23    23    23
    26    31    33    32    33    33    32    32    32    32    32    32    32    29    29    29    29    30    30    30    30    33    33    33    33    33    33    33
    22    26    29    28    28    29    29    29    29    29    29    29    29    28    28    28    28    27    27    27    29    29    29    29    29    29    29    29
    19    24    27    25    25    26    27    27    27    27    27    27    27    30    30    30    30    29    29    29    28    28    28    28    26    26    26    26
    24    29    32    30    31    31    31    31    31    31    31    31    31    34    34    33    33    32    32    31    31    31    31    31    31    31    31    31    31
    24    29    31    30    30    31    28    28    28    28    28    28    28    29    28    28    27    26    26    25    25    30    30    30    30    30    30    30
    24    29    30    28    29    28    28    28    28    28    28    28    28    30    30    30    30    30    30    30    30    29    29    29    29    29    29    29
    24    29    30    28    29    28    28    28    28    28    28    28    28    30    30    30    30    30    30    30    30    30    30    30    30    30    30    30
    24    29    30    28    29    28    28    28    28    28    28    28    28    30    30    30    30    30    30    30    30    32    32    32    32    32    32    32
    24    29    30    28    29    28    28    28    28    28    28    28    28    30    30    30    30    30    30    30    30    31    31    31    31    31    31    31
    24    29    30    28    29    28    28    28    28    28    28    28    28    30    30    30    30    30    30    30    30    29    29    29    29    29    29    29
    24    29    30    28    29    28    28    28    28    28    28    28    28    30    30    30    30    30    30    30    30    30    30    30    30    30    30    30
    24    29    30    28    29    28    28    28    28    28    28    28    28    30    30    30    30    30    30    30    30    31    31    31    31    31    31    31
    24    29    30    28    29    29    30    29    27    26    26    27    29    29    29    29    29    30    30    30    30    30    30    30    30    30    30    30    30
    
```

Sumber: hasil penelitian (2020)

Gambar 3.6 Matrix Grayscale Citra jasmine1

3.5. Metode Yang Diusulkan

Pada penelitian ini dilakukan proses identifikasi pada citra beras impor dengan melakukan perbandingan pada algoritma *Multi-Support Vector Machine (Multi-SVM)* dan *Neural Network*. Proses pada penelitian ini akan diimplementasikan menggunakan *software* aplikasi MATLAB R2015a. Tahap pertama pada penelitian ini adalah dengan melakukan prapemrosesan citra dengan

konversi citra dari RGB menjadi *grayscale*. Tahap kedua dengan melakukan segmentasi pada citra untuk memisahkan antara objek penelitian dan background atau objek yang tidak dibutuhkan pada citra untuk dilakukan proses selanjutnya. Segmentasi pada penelitian ini menggunakan metode K-Means Clustering lalu mengubahnya atau dilakukan konversi citra menjadi citra biner untuk diambil nilai fitur. Tahap ketiga adalah ekstraksi fitur yaitu mengambil nilai fitur dari citra dengan menggunakan metode *Gray-Level Co-Occurrence Matrix (GLCM)* yang terdiri dari 4 properti terpilih yaitu *eccentricity*, *contrast*, *homogeneity* dan *correlation* dikombinasikan dengan fitur morfologi menggunakan *regionprop* yang terdiri dari 5 properti terpilih yaitu *area*, *perimeter*, *metric*, *major axis length*, dan *minor axis length*. Setelah didapatkan nilai fitur dari masing-masing citra tahap selanjutnya adalah mengidentifikasi dengan dua algoritma, pertama dengan algoritma *Multi-Support Vector Machine (Multi-SVM)* dan *Neural Network* yang diimplementasikan menggunakan *software* aplikasi MATLAB R2015a. Tahap terakhir adalah melakukan pengujian menggunakan GUI untuk mengetahui bagaimana keakuratan aplikasi yang dibuat dalam melakukan identifikasi citra jenis beras impor tersebut.

3.6. Eksperimen dan Pengujian Metode

Tahapan eksperimen yang dilakukan untuk menghasilkan identifikasi yang baik pada penelitian ini adalah sebagai berikut:

1. Mengumpulkan jenis beras impor dari pasar Indonesia yang menjadi objek penelitian untuk dilakukan digitalisasi citra.
2. Akuisisi objek penelitian menjadi citra digital dengan menggunakan metode *flatbed scanning*.
3. Melakukan *cropping* citra, penamaan citra dan menyimpannya dengan format PNG (*Portable Network Graphics*) pada citra hasil akuisisi menggunakan *software* aplikasi *CorelDRAW Graphic Suite X7*.
4. Membagi citra yang telah ditentukan sebagai dataset penelitian menjadi dua bagian, yaitu citra data training 70% dan citra data testing 30%.
5. Membuat rancangan aplikasi menggunakan *software* aplikasi MATLAB R2015a versi M-File, untuk melakukan prapemrosesan citra pada data

training dengan konversi citra RGB menjadi *Grayscale* dan proses segmentasi dengan *K-Means Clustering* dan konversi biner untuk selanjutnya dilakukan pengambilan nilai fitur menggunakan metode *Gray Level Co-occurrence Matrix (GLCM)* dan fitur morfologi dengan *regionprops* sehingga menghasilkan akurasi yang baik untuk dilakukan pemrosesan pada data testing.

6. Melakukan identifikasi dengan MATLAB menggunakan algoritma *Multi-Support Vector Machine (Multi-SVM)* dan *Neural Network*.
7. Membangun aplikasi versi GUI (*Graphical User Interface*) pada *software* aplikasi MATLAB 2015a, yang terdiri dari pemrosesan citra mulai dari tahap pra-pemrosesan sampai hasil identifikasi sesuai eksperimen yang diajukan.

Dalam melakukan penelitian ini dibutuhkan *tools* atau alat penunjang baik perangkat keras maupun perangkat lunak untuk melakukan akuisisi citra dan pemrosesan citra hingga menghasilkan tujuan dari penelitian ini. Berikut adalah spesifikasi *hardware* yang dibutuhkan untuk melakukan penelitian ini:

1. Spesifikasi Perangkat Keras
 - a. CPU / Komputer
 - 1) Processor Intel® Pentium® Dual Core
 - 2) RAM DDR III 4 GB
 - 3) Hard Disk 500 GB
 - 4) VGA 1,5 GB
 - b. Monitor dengan resolusi layar minimum 1024x768
 - c. Canon Pixma MG2570S
 - 1) Scan resolution 600 x 1200 dpi
 - 2) Print resolution 4800 x 1200 dpi
2. Spesifikasi Perangkat Lunak
 - a. Sistem operasi yang umum digunakan seperti: Microsoft Windows atau Linux (Ubuntu, Fedora, dan lain-lain), dianjurkan Microsoft Windows.
 - b. MATLAB R2015a

- c. *IJ Scan Utility*
- d. *CorrelDRAW Ghrapical Suite X7*

3.7. Evaluasi dan Validasi

Pada tahap evaluasi dan validasi ini dilakukan pengujian dan pemrosesan yang sama seperti pada data training terhadap citra baru atau data testing untuk mengetahui seberapa besar keakuratan aplikasi yang telah dibuat menggunakan GUI MATLAB dalam melakukan identifikasi jenis beras impor dan ekstraksi nilai fitur masing-masing citra menggunakan metode sesuai dengan eksperimen yang dilakukan dan algoritma yang dipilih pada citra butir beras impor Indonesia.

BAB IV HASIL PENELITIAN

Pada penelitian ini penulis menggunakan aplikasi MATLAB R2015a dalam melakukan pengolahan citra dalam bentuk *Graphical User Interface* (GUI) untuk tahap pra-pemrosesan, segmentasi, ekstraksi fitur pada citra dan penggunaan algoritma untuk identifikasi.

4.1. Hasil Segmentasi

Pada tahap segmentasi, peneliti melakukan pemisahan antara objek penelitian serta objek bukan penelitian yang meliputi *background* dan *noise* pada citra butir beras menggunakan Algoritma K-Means dan mengubah dimensi citra menjadi citra biner. Langkah segmentasi menggunakan K-Means dan Konversi Biner ini belum dilakukan pada penelitian sebelumnya[7][13][49][50], adapun penelitian sebelumnya hanya melakukan segmentasi dengan metode *Thresholding*[51][52].

Pada segmentasi menggunakan algoritma K-Means ini, citra diproses dan ditampilkan dengan 2 kluster citra hasil segmentasi. Dari hasil segmentasi tahap pertama tersebut, kluster 2 dinyatakan lebih baik dibandingkan kluster 1 karena memudahkan pada proses konversi biner dan memisahkan dengan baik antara objek yang akan diteliti pada citra dengan bukan objek penelitian. Berikut pada Tabel 4.1 adalah hasil segmentasi citra dengan K-Means pada kluster 1 dan 2:

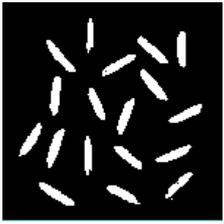
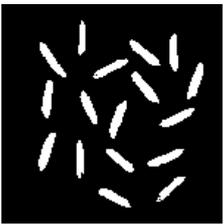
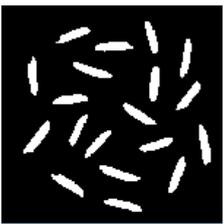
Tabel 4.1 segmentasi Citra Beras dengan K-Means

Citra Awal	Segmentasi	
	K-Means Cluster 1	K-Means Cluster 2
		

Sumber: Hasil penelitian (2020)

Setelah dipilih citra hasil segmentasi dengan K-Means pada kluster 2, maka dilakukan konversi citra dari RGB menjadi citra biner. Berikut pada Tabel 4.2 ditampilkan hasil segmentasi citra untuk beras jenis basmati:

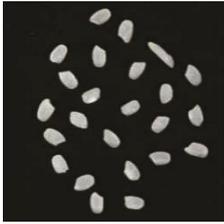
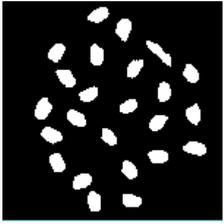
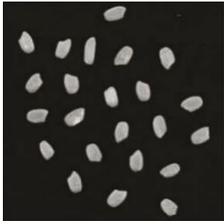
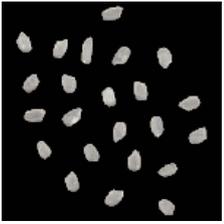
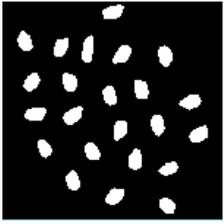
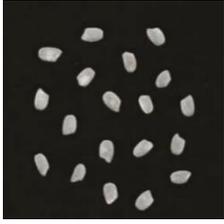
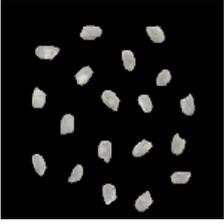
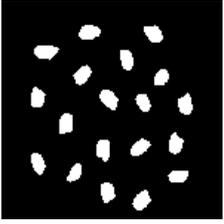
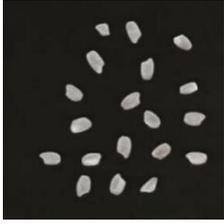
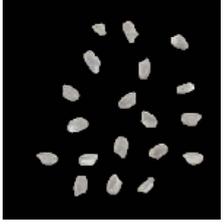
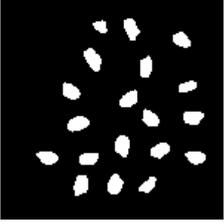
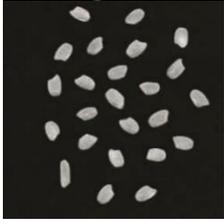
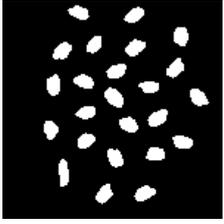
Tabel 4.2 Segmentasi Citra Butir Beras Basmati

Citra Awal	Segmentasi	
	K-Means (Cluster 2)	Konversi Biner
		
		
		
		
		

Sumber: Hasil penelitian (2020)

Pada Tabel 4.3 di bawah ini adalah hasil segmentasi menggunakan K-Means pada kluster 2 dan konversi biner yang dilakukan pengujian pada citra beras jenis japonica:

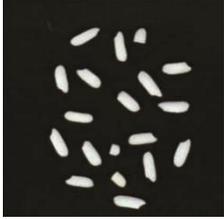
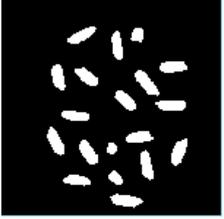
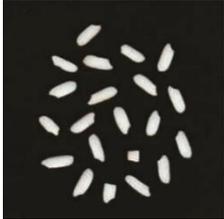
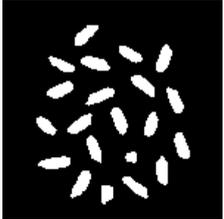
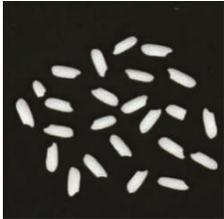
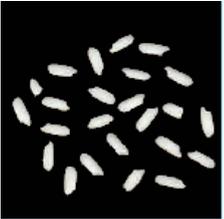
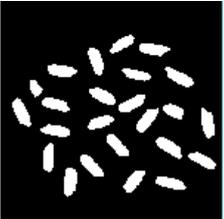
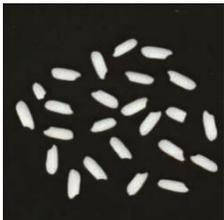
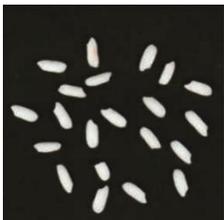
Tabel 4.3 Segmentasi Citra Butir Beras Japonica

Citra Awal	Segmentasi	
	K-Means (Cluster 2)	Konversi Biner
		
		
		
		
		

Sumber: Hasil penelitian (2020)

Pada Tabel 4.4 ditampilkan juga hasil segmentasi pada citra beras jenis jasmine menggunakan metode segmentasi K-Means dan Konversi biner:

Tabel 4.4 Segmentasi Citra Butir Beras Jasmine

Citra Awal	Segmentasi	
	K-Means (Cluster 2)	Konversi Biner
		
		
		
		
		

Sumber: Hasil penelitian (2020)

4.2. Ekstraksi Ciri

Pada Tahap ekstraksi citra, data citra yang telah dilakukan segmentasi diturunkan atau ditampilkan nilai-nilai yang menjadi bahan pengujian untuk identifikasi. Pada penelitian ini metode fitur morfologi dengan *Regionprop* dan *Gray Level Co-Occurance Method (GLCM)* dipilih sebagai metode ekstraksi citra untuk identifikasi jenis citra butir beras. Terdapat 9 fitur yang dihasilkan dari kombinasi metode *Regionprops* dan GLCM yang meliputi *eccentricity*, *contrast*, *homogeneity*, *correlation*, *Area*, *Perimeter*, *Metric*, *Major Axis Length*, dan *Minor Axis Length* yang diujikan pada 63 data training dan 27 data testing. Berikut pada Tabel hasil ekstraksi ciri untuk masing-masing sampel jenis beras:



Sumber: Hasil penelitian (2020)

Gambar 4.1 Nilai Ciri Perbutir Basmati

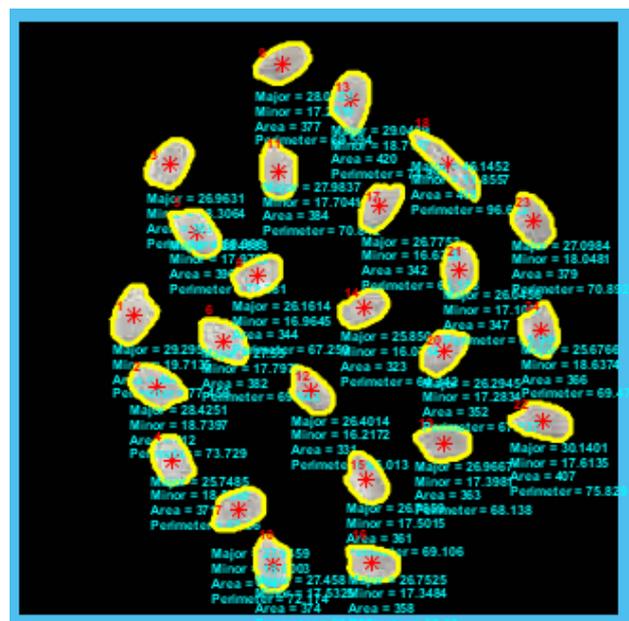
Pada Gambar 4.1 dapat dilihat untuk nilai fitur morfologi dari masing-masing butir beras pada citra. Setelah diketahui masing-masing nilainya, maka dikalkulasikan dan diambil nilai untuk menentukan nilai ciri keseluruhan. Berikut pada Tabel 4.5 nilai ciri total untuk seluruh butir pada citra sampel untuk beras jenis basmati:

Tabel 4.5 Nilai Ciri Basmati

Nama Ciri	Nilai
Area	136
Perimeter	105.842
MajorAxisLength	49.8609
MinorAxisLength	6.2081
Metric	0.15256
Eccentricity	0.99222
Contrast	0.38301
Homogeneity	0.96522
Correlation	0.75858

Sumber: Hasil penelitian (2020)

Dari Tabel 4.5 dapat dilihat nilai ciri untuk sampel beras basmati yaitu untuk fitur morfologi meliputi *Area* sebesar 136, *Perimeter* 105.842, *Major Axis Length* 49.8609, *Minor Axis Length* lebih kecil dari *Major Axis Length* sebesar 6.2081, *Metric* 0.15256, serta nilai dari GLCM meliputi *Eccentricity* 0.99222, nilai *Contrast* 0.38301, *Homogeneity* 0.96522 dan nilai *Correlation* sebesar 0.75858.



Sumber: Hasil penelitian (2020)

Gambar 4.2 Nilai Ciri Perbutir Japonica

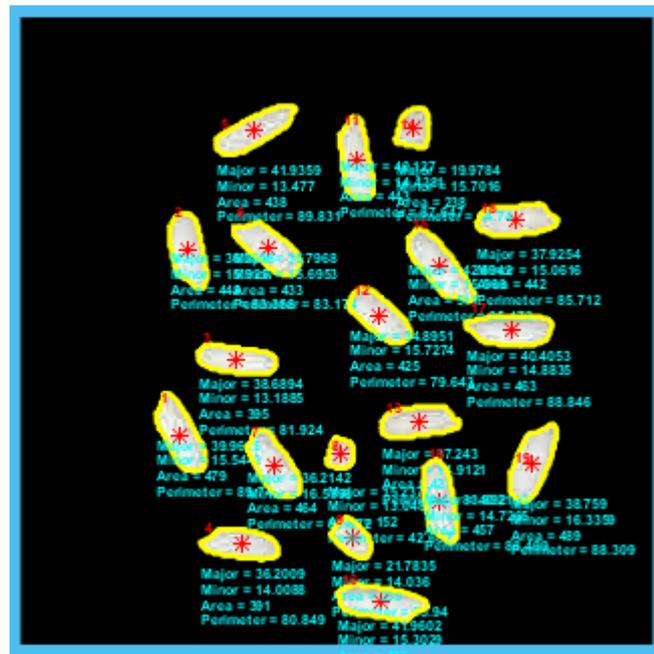
Dari Gambar 4.2 dapat dilihat untuk nilai fitur morfologi dari masing-masing butir citra beras jenis japonica. Selain daripada memunculkan nilai fitur, dapat dilihat juga jumlah butir beras yang dilakukan pengujian pada citra japonica tersebut dengan melihat nomor dari label yang ditandai warna merah. Tepi dari masing-masing citra diberi tanda warna kuning untuk membedakan dengan butir lainnya. Setelah didapat nilai fitur dari masing-masing butir, maka dilakukan penghitungan total untuk mengetahui nilai ciri dari citra yang meliputi keseluruhan butir, berikut pada Tabel 4.6 ditampilkan hasil dari nilai ciri sampel citra untuk beras jenis japonica:

Tabel 4.6 Nilai Ciri Japonica

Nama Ciri	Nilai
Area	122
Perimeter	109.399
MajorAxisLength	35.9343
MinorAxisLength	11.8328
Metric	0.1281
Eccentricity	0.94423
Contrast	0.43817
Homogeneity	0.97402
Correlation	0.59284

Sumber: Hasil penelitian (2020)

Selanjutnya, dapat dilihat juga dari Tabel 4.6 untuk nilai ciri dari sampel beras japonica yang diujikan meliputi fitur morfologi yang terdiri dari nilai *Area* sebesar 122, nilai *Perimeter* sebesar 109.399, *Major Axis Length* sebesar 35.9343, nilai *Minor Axis Length* sebesar 11.8328 dan *Metric* sebesar 0.1281. Untuk nilai dari fitur GLCM terdiri dari nilai *Eccentricity* sebesar 0.94423, *Contrast* sebesar 0.43817, nilai *Homogeneity* sebesar 0.97402, dan nilai ciri *Correlation* sebesar 0.59284



Sumber: Hasil penelitian (2020)

Gambar 4.3 Nilai Ciri Perbutir Jasmine

Gambar 4.3 menunjukkan nilai ciri morfologi perbutir dari citra beras jenis ketiga yaitu jasmine. Setelah diketahui nilai ciri masing-masing butir maka dikalkulasikan dengan mengambil nilai untuk citra seluruh butir yang ditampilkan pada Tabel 4.6 berikut:

Tabel 4.6 Nilai Ciri Jasmine

Nama Ciri	Nilai
Area	64
Perimeter	34.916
MajorAxisLength	18.4752
MinorAxisLength	4.6188
Metric	0.65969
Eccentricity	0.96825
Contrast	0.56872
Homogeneity	0.96565
Correlation	0.69472

Sumber: Hasil penelitian (2020)

Dari Tabel 4.6 dapat dilihat nilai ciri untuk citra jenis jasmine dengan nilai citra morfologi yang terdiri dari nilai ciri *Area* sebesar 64, *Perimeter* 34.916, *Major Axis Length* sebesar 18.4752, *Minor Axis Length* sebesar 4.6188, jumlah nilai *Metric* 0.65969, dan nilai ciri untuk GLCM meliputi ciri *Eccentricity* 0.96825, nilai *Contrast* 0.56872, *Homogeneity* 0.96565, dan nilai *Correlation* 0.69472.

4.3. Hasil Identifikasi

Tahap identifikasi melakukan pengujian pada citra uji butir beras berjumlah 27 dengan masing-masing varietas 9 citra. Identifikasi dilakukan dengan dua algoritma yaitu *Multi-SVM* dan *Neural Network*. Berikut pada Tabel 4.7 adalah hasil identifikasi pada citra beras basmati:

Tabel 4.7 Identifikasi Citra Beras Basmati

Citra Ke-	1	2	3	4	5	6	7	8	9
Citra Uji									
Area	262	394	201	549	249	247	350	361	287
Perimeter	176.83 2	194.53 2	157.52 4	117.85	215.728	229.921	221.203	167.31 5	179.17 4
Major Axis Length	56.171 9	49.675 5	52.819 3	55.604 2	43.3272	48.7986	51.4033	38.955 3	62.842 1
Minor Axis Length	12.490 7	16.384 2	12.033 3	12.908 7	15.6566	16.5166	14.3304	14.995 7	12.362 5
Metric	0.1052 9	0.1308 4	0.1017 9	0.4967 3	0.06723 5	0.05871 5	0.08988 7	0.1620 5	0.1123 4
Eccentricity	0.9749 6	0.9440 4	0.9737	0.9726 8	0.93243	0.94098	0.96035	0.9229 4	0.9804 6
Contrast	0.4863 9	0.4386 9	0.3856 2	0.4734 6	0.50191	0.45753	0.36964	0.4177 3	0.4207 2
Homogeneity	0.9566 9	0.9602 1	0.9611 9	0.9604 7	0.95455	0.95868	0.96342	0.9627 6	0.9621 3
Correlation	0.7598 3	0.7631 3	0.7971 7	0.8210 2	0.77958	0.777	0.81595	0.7779 5	0.7655
Identifikasi									
Multi-SVM	Basmati	Basmati	Basmati	Basmati	Basmati	Basmati	Basmati	Basmati	Basmati
NN	Basmati	Basmati	Basmati	Jasmine	Basmati	Basmati	Basmati	Basmati	Basmati

Sumber: Hasil penelitian (2020)

Pada Tabel 4.7 dapat dilihat hasil identifikasi untuk citra beras dengan menggunakan masing-masing algoritma *Multi-SVM* dan *Neural Network*. Pada pengujian identifikasi untuk beras jenis basmati ini, algoritma *Multi-SVM* menunjukkan hasil identifikasi sesuai dengan prediksi pada semua citra. Sedangkan pada hasil identifikasi menggunakan algoritma *Neural Network* terdapat satu citra yang tidak terbaca sebagai jenis beras aktual, satu jenis tersebut terbaca sebagai jenis lain yaitu jenis beras ketiga jasmine.

Tabel 4.8 Identifikasi Citra Beras Japonica

Citra Ke-	1	2	3	4	5	6	7	8	9
Citra Uji									
Area	19253	129	112	23851	4361	13089	787	3481	628
Perimeter	2152.49	250.88	109.11	5230.36	1862.36	3529.08	1146.651	763.36	504.184
Major Axis Length	230.048	148.956	34.844	340.635	346.89	333.873	304.4017	151.007	149.461
Minor Axis Length	145.240	1.1547	15.261	331.205	27.867	140.217	6.7326	64.03	13.9125
Metric	0.05221 8	0.02575 5	0.1182	0.01095 6	0.0158	0.01320 7	0.007521 8	0.07506 8	0.03104 5
Eccentricity	0.7755	0.99997	0.8989 8	0.23367	0.9967 7	0.90754	0.99976	0.90565	0.99566
Contrast	0.47198	0.29935	0.2880 7	0.35965	0.5444	0.50525	0.69342	0.29396	0.4593
Homogeneity	0.95258	0.97872	0.9784 7	0.97219	0.9722 6	0.96012	0.96711	0.97838	0.96582
Correlation	0.8558	0.63882	0.5851 4	0.69093	0.7664 4	0.73745	0.78655	0.61692	0.79251
Identifikasi									
Multi-SVM	Japonica	Japonica	Jasmine	Japonica	aponica	Japonica	Japonica	aponica	aponica
NN	Japonica	Japonica	Japonica	Basmati	aponica	Japonica	Japonica	Jasmine	aponica

Sumber: Hasil penelitian (2020)

Dilihat pada Tabel 4.8 yang menampilkan hasil identifikasi pada citra uji beras jenis japonica terdapat beberapa hasil yang tidak sesuai dengan prediksi. Pengolahan menggunakan algoritma *Multi-SVM* menampilkan hasil identifikasi pada 8 citra sebagai citra beras jenis japonica dan satu citra terbaca sebagai citra beras jenis jasmine. Pada algoritma kedua yaitu algoritma Neural Network menampilkan hasil sesuai prediksi pada 7 citra, 1 citra terbaca sebagai jasmine dan 1 citra sebagai basmati.

Selanjutnya hasil identifikasi pada jenis citra beras ketiga yaitu jasmine yang ditampilkan pada Tabel 4.9 berikut:

Tabel 4.9 Identifikasi Citra Beras Jasmine

Citra Ke-	1	2	3	4	5	6	7	8	9
Citra Uji									
Area	255	294	180	54	940	109	249	100	1520
Perimeter	130.016	143.298	129.198	45.519	504.179	95.481	128.824	105.602	1010.57
Major Axis Length	33.796	40.2405	33.9239	21.9641	92.0104	44.5584	34.1071	22.6552	268.537 2
Minor Axis Length	12.386	12.1976	10.0291	4.9898	25.6317	8.556	11.4046	12.4007	34.5342
Metric	0.18956	0.17992	0.13551	0.32751	0.04647	0.15025	0.18855	0.11268	0.01870 3
Eccentricity	0.93042	0.95295	0.9553	0.97385	0.96041	0.98139	0.94244	0.83689	0.9917
Contrast	1.1293	1.0968	0.87519	0.30312	0.85372	0.40541	0.75918	0.82154	0.81282
Homogeneity	0.96473	0.96591	0.9734	0.984	0.95784	0.97416	0.98012	0.97735	0.95936
Correlation	0.81048	0.81809	0.80014	0.5719	0.86673	0.5228	0.73425	0.75521	0.85371
Identifikasi									
Multi-SVM	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine
NN	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine	Jasmine

Sumber: Hasil penelitian (2020)

Dapat dilihat dari Tabel 4.9 kedua algoritma menampilkan hasil identifikasi sesuai dengan prediksi pada semua citra. Algoritma *Multi-SVM* mengidentifikasi citra yang diujikan dengan sesuai hasil prediksi yaitu beras jenis jasmine pada seluruh citra uji berjumlah 9, begitupun hasil pengujian menggunakan algoritma *Neural Network* menunjukkan hasil yang sesuai pula pada kesembilan citra uji dengan hasil identifikasi jenis beras jasmine.

4.4. Evaluasi dan Validasi Hasil

Setelah diketahui hasil pengujian dengan algoritma Multi-SVM dan Neural Network, maka pada tahap ini dilakukan evaluasi dan validasi kembali hasil dari identifikasi yang telah dilakukan pada citra uji dengan total 27 citra. Berikut dijelaskan pada Tabel 4.10 untuk penjabaran citra yang telah teridentifikasi menggunakan algoritma *Multi-SVM*:

Tabel 4.10 Penjabaran Citra Teridentifikasi dengan Multi-SVM

No	Jenis Citra Beras	Identifikasi Benar	Identifikasi Salah
1	Basmati	9	0
2	Japonica	8	1
3	Jasmine	9	0

Sumber: Hasil penelitian (2020)

Dari Tabel 4.10 dapat dilihat bahwa Algoritma Multi-SVM mengidentifikasi dengan baik pada jenis beras basmati dan jasmine sehingga seluruh citra uji teridentifikasi, namun ada 1 citra japonica yang tidak terdeteksi sesuai dengan prediksi.

Selanjutnya, setelah penjabaran dengan Algoritma Multi-SVM di atas, berikut pada Tabel 4.11 mengenai penjabaran citra yang telah teridentifikasi menggunakan Algoritma *Neural Network*:

Tabel 4.11 Penjabaran Citra Teridentifikasi dengan Neural Network

No	Jenis Citra Beras	Identifikasi Benar	Identifikasi Salah
1	Basmati	8	1
2	Japonica	7	2
3	Jasmine	9	0

Sumber: Hasil penelitian (2020)

Proses selanjutnya setelah diketahui penjabaran citra yang telah teridentifikasi sesuai dengan aturan-aturan yang dilakukan dalam pengujian sampai hasil identifikasi, adalah proses evaluasi menggunakan *confusion matrix*. Evaluasi dengan *confusion matrix* dilakukan padakedua algoritma untuk menarik hasil akurasi dari masing-masing algoritma. Berikut pada Tabel 4.12 mengenai hasil identifikasi citra, aktual dan hasil prediksi:

Tabel 4.12 Hasil Identifikasi Citra dengan *Multi-SVM*

Aktual	Hasil Prediksi		
	Basmati	Japonica	Jasmine
Basmati	9	0	0
Japonica	0	8	1
Jasmine	0	0	9

Sumber: Hasil penelitian (2020)

Setelah diketahui dari Tabel 4.12 mengenai hasil identifikasi yang digambarkan pada tabel *confusion matrix*, maka dapat dilakukan perhitungan akurasi untuk hasil pengujian dalam identifikasi citra butir beras dengan menggunakan algoritma *Multi-SVM* pada persamaan di bawah:

$$TP = 26, FP = 0, TN = 0, FN = 1$$

$$\text{Akurasi} = ((TP+TN)/(TP+FP+TN+FN))*100\%$$

$$\text{Akurasi} = ((26+0)/(26+0+0+1))*100\%$$

$$\text{Akurasi} = ((26)/27)*100\%$$

$$\text{Akurasi} = 96,296\%$$

Selanjutnya, setelah mengetahui akurasi untuk Algoritma *Multi-SVM*, Pada Tabel 4.13 digambarkan juga tabel *confussion matrix* untuk pengujian identifikasi menggunakan algoritma *Neural Network*:

Tabel 4.13 Hasil Identifikasi Citra dengan *Neural Network*

Aktual	Hasil Prediksi		
	Basmati	Japonica	Jasmine
Basmati	8	0	1
Japonica	1	7	1
Jasmine	0	0	9

Sumber: Hasil penelitian (2020)

Dari Tabel 4.12 di atas dapat dilakukan perhitungan untuk nilai akurasi pengujian menggunakan Algoritma Neural Network, seperti pada persamaan di bawah ini:

$$TP = 24, FP = 0, TN = 0, FN = 3$$

$$\text{Akurasi} = ((TP+TN)/(TP+FP+TN+FN))*100\%$$

$$\text{Akurasi} = ((24+0)/(24+0+0+3))*100\%$$

$$\text{Akurasi} = ((24)/27)*100\%$$

$$\text{Akurasi} = 88,89\%$$

4.5. Hasil Komparasi Algoritma Multi-SVM dan Neural Network

Setelah dilakukan identifikasi pada setiap citra uji, maka dapat disimpulkan untuk akurasi masing-masing varietas, seperti digambarkan pada Tabel 4.10 berikut:

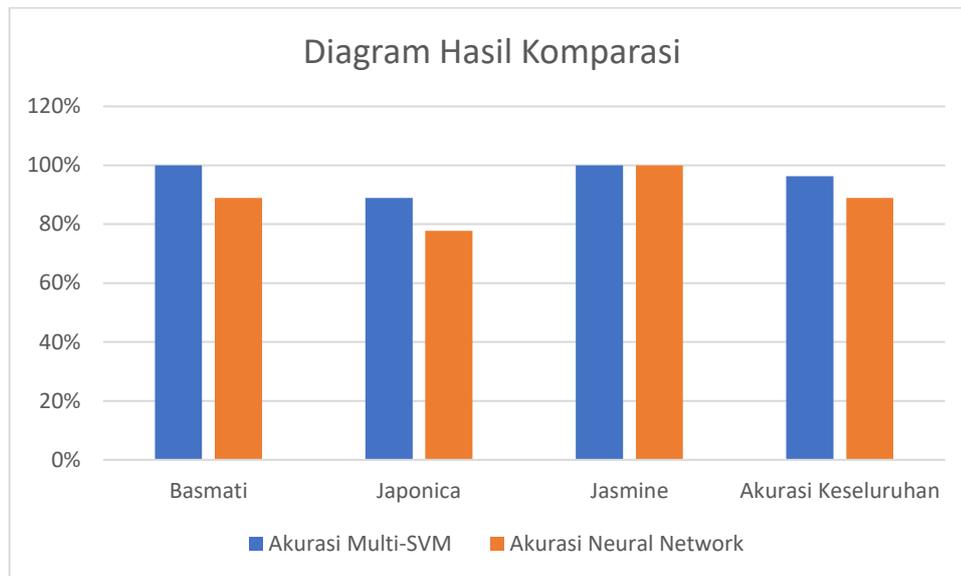
Tabel 4.14 Hasil Komparasi

Varietas Citra Beras	Jumlah Citra Uji	Deteksi Akurasi	
		Multi-SVM	Neural Network
Basmati	9	100%	88,89%
Japonica	9	88,89%	77,78
Jasmine	9	100%	100%
Akurasi Keseluruhan		96,296	88,89%

Sumber: Hasil penelitian (2020)

Dari tabel 4.10 di atas dapat disimpulkan bahwa perhitungan akurasi untuk identifikasi jenis beras impor dengan citra butir beras menggunakan algoritma Multi-SVM lebih unggul dengan besar akurasi 96,296% yang terdiri dari akurasi hasil identifikasi pada jenis beras basmati sebesar 100% dari 9 total citra yang diujikan, 88,89% untuk identifikasi pada beras japonica yang diujikan pada 9 total citra, dan ketiga beras jasmine dengan besar akurasi 100% yang sama diujikan pada 9 citra. Sedangkan untuk Algoritma Neural Network pada pengolahan 9 citra uji basmati lebih rendah yaitu 88,89%, untuk pengujian pada citra beras jenis Japonica akurasi yang dihasilkan adalah 77,78% masih lebih rendah daripada hasil identifikasi Algoritma *Multi-SVM*, dan terakhir untuk pengujian pada citra beras jenis jasmine menghasilkan akurasi tinggi yaitu 100% sama dengan hasil identifikasi menggunakan algoritma *Multi-SVM*.

Berikut untuk diagram hasil komparasi identifikasi citra beras dengan menggunakan Algoritma Multi-SVM dan Neural Network pada Gambar 4.4:



Sumber: Hasil penelitian (2020)

Gambar 4.4 Diagram Hasil Komparasi

Dari pembahasan di atas dapat diketahui bahwa *rules* dan metode yang digunakan dalam penelitian ini mulai dari tahap prapemrosesan dengan konversi citra dari RGB ke *Grayscale*, proses segmentasi dengan K-Means dan Konversi Biner dapat membantu mendeteksi objek penelitian untuk ekstraksi fitur dan identifikasi. Ekstraksi fitur atau ciri yang menggunakan fitur morfologi dan GLCM dapat dilakukan pada citra butir beras serta dapat dirancang untuk aplikasi identifikasi jenis beras impor dengan citra butir beras.

BAB V

PENUTUP

Pada bagian ini dijelaskan mengenai kesimpulan secara ringkas dari hasil penelitian yang telah dilakukan dan beberapa saran yang dapat diaplikasikan untuk penelitian selanjutnya.

5.1. Kesimpulan

Berdasarkan permasalahan yang telah dipaparkan dan diidentifikasi sebelumnya, maka penulis dapat mengambil kesimpulan dari penelitian yang telah dilakukan bahwa:

1. Segmentasi pada citra butir beras sebanyak 63 data citra training dan 27 data citra testing menggunakan Algoritma K-Means pada kluster kedua dapat melakukan segmentasi dengan baik. Penambahan konversi citra dari *grayscale* ke biner dalam tahap segmentasi menghasilkan citra tersegmentasi yang baik dan dapat memisahkan antara objek penelitian atau *region of interest* dan bukan objek penelitian seperti *background* dan *noise*.
2. Selain hasil segmentasi yang baik, pada penelitian ini juga dapat disimpulkan bahwa penggunaan fitur morfologi yang terdiri dari 5 properti *regionprops* yaitu *Area*, *Perimeter*, *Metric*, *Major Axis Length*, dan *Minor Axis Length* dikombinasikan dengan fitur *Gray Level Co-Occurance Method* (GLCM) yang terdiri dari 4 properti yaitu *Eccentricity*, *Contrast*, *Homogeneity* dan *Correlation* menghasilkan total 9 fitur yang dapat memberikan nilai ciri masing-masing yang baik dan beda pada setiap varietas citra beras sehingga dapat memudahkan dalam melakukan identifikasi pada masing-masing varietas.
3. Identifikasi menggunakan Algoritma *Multi-SVM* dan *Neural Network* yang diujikan pada citra yang telah diketahui nilai citranya menghasilkan akurasi yang cukup tinggi pada keduanya.
4. Kesimpulan akhir dalam identifikasi menggunakan Algoritma *Multi-SVM* dinyatakan lebih unggul dengan besar akurasi 96,296% dibanding hasil

identifikasi menggunakan algoritma *Neural Network* dengan besar akurasi 88,89%.

5.2. Saran

Berikut adalah beberapa saran yang dapat diaplikasikan untuk penelitian selanjutnya agar menghasilkan penelitian yang lebih baik dalam segmentasi, identifikasi atau proses lainnya:

1. Untuk dataset citra beras, diharapkan dapat menambahkan jenis beras dari berbagai negara lain yang tidak hanya mayoritas dalam beras impor tapi seluruh beras impor atau lebih banyak lagi dari penelitian yang telah dilakukan
2. Pada ekstraksi ciri menggunakan fitur morfologi dengan 5 properti *regionprops* dan 4 properti GLCM dapat menambahkan metode ekstraksi fitur lain atau menambahkan properti dari metode ekstraksi fitur yang dilakukan pada penelitian ini.
3. Dapat membandingkan kualitas beras dari ketiga negara yang diteliti dengan beras lokal Indonesia berdasarkan warna dan bentuk beras atau fitur yang telah dilakukan.
4. Menambahkan algoritma lain dalam identifikasi sehingga dapat dilakukan perbandingan hasil identifikasi yang lebih banyak.

DAFTAR REFERENSI

- [1] J. Alzeer, U. Rieder, and K. Abou, "Trends in Food Science & Technology Rational and practical aspects of Halal and Tayyib in the context of food safety," *Trends Food Sci. Technol.*, no. August, pp. 0–1, 2017.
- [2] N. Bandumula, "Rice Production in Asia : Key to Global Food Security," *Proc. Natl. Acad. Sci. India Sect. B Biol. Sci.*, 2017.
- [3] N. W. Childs, "Rice Outlook U . S . Rice Export Forecasts Lowered for Both," 2020.
- [4] S. Sabarella *et al.*, "Buletin Konsumsi," *Pus. Data dan Sist. Inf. Pertan. Sekr. Jenderal Kementerian. Pertan.*, vol. 10, no. 1, 2019.
- [5] Badan Pusat Statistik, "Impor Beras Menurut Negara Asal Utama , 2000-2019," 2020.
- [6] Menteri Perdagangan Republik Indonesia, "Peraturan Menteri Perdagangan Republik Indonesia Nomor 19/M-DAG/PER/3/2014."
- [7] D. Ricardo and Gasim, "Perbandingan Akurasi Pengenalan Jenis Beras dengan Algoritma Propogasi Balik pada Beberapa Resolusi Kamera," vol. 1, no. 10, pp. 1–8, 2019.
- [8] M. Z. Abidin, "Dampak kebijakan impor beras dan ketahanan pangan dalam perspektif kesejahteraan sosial," pp. 213–230, 2015.
- [9] R. Mumm, J. A. H. M. N. Calingacion, and R. C. H. De Vos, "Multi-platform metabolomics analyses of a broad collection of fragrant and non-fragrant rice varieties reveals the high complexity of grain quality characteristics," *Metabolomics*, vol. 12, no. 2, pp. 1–19, 2016.
- [10] G. Mahajan, A. Matloob, and R. Singh, *Basmati Rice in the Indian Subcontinent : Strategies to Boost Production and Quality Traits*, vol. 151. Elsevier Ltd, 2018.
- [11] N. Patel, "Rice Quality Analysis Based on Physical Attributes Using Image Processing Technique," 2017.
- [12] P. Kongsawat, "Quality Assessment of Thai Rice Kernels Using Low Cost Digital Image Processing System," 2018.

- [13] T. G. Devi, "Image processing based rice plant leaves diseases in Thanjavur , Tamilnadu," *Cluster Comput.*, vol. 3456789, 2018.
- [14] F. Perez-sanz, P. J. Navarro, and M. Egea-cortines, "Plant phenomics : an overview of image acquisition technologies and image data analysis algorithms," *Gigascience Rev.*, 2017.
- [15] M. Z. Abdullah, *Image Acquisition Systems*. Elsevier Inc., 2016.
- [16] S. Mahajan, A. Das, and H. K. Sardana, "Image acquisition techniques for assessment of legume quality," *Trends Food Sci. Technol.*, vol. 42, no. 2, pp. 116–133, 2015.
- [17] Z. Wang, Q. Zeng, L. Wang, K. Li, S. Xu, and Y. Yao, "Characterizing frost damages of concrete with flatbed scanner," vol. 102, pp. 872–883, 2016.
- [18] R. Ruslan, A. A. Aznan, F. A. Azizan, N. Roslan, and N. Zulkifli, "Extraction of Morphological Features of Malaysian Rice Seed Varieties Using Flatbed Scanner," *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 8, no. 1, 2018.
- [19] J. Chen, D. Lopresti, and G. Nagy, "Conservative preprocessing of document images," *Int. J. Doc. Anal. Recognit.*, 2016.
- [20] A. Putera and U. Siahaan, "RC4 Technique in Visual Cryptography RGB Image Encryption," vol. 3, no. 7, pp. 3–8, 2016.
- [21] L. Indriyani, W. Susanto, and D. Riana, "Aplikasi Matlab Pada Pengukuran Diameter," vol. 2, no. 1, pp. 46–52, 2017.
- [22] M. Bouillon, R. Ingold, and M. Liwicki, "Grayification : A meaningful grayscale conversion to improve handwritten historical documents analysis," *Pattern Recognit. Lett.*, vol. 0, pp. 1–6, 2018.
- [23] U. D. Dixit, "Preprocessing Framework for Document Image Analysis," vol. 3918, pp. 3911–3918, 2019.
- [24] T. A. Keziah and P. Haseena, "Lung Cancer Detection Using SVM Classifier and MFPCM Segmentation," pp. 3114–3118, 2018.
- [25] S. Hore, S. Chakraborty, S. Chatterjee, and N. Dey, "An Integrated Interactive Technique for Image Segmentation using Stack based Seeded Region Growing and Thresholding," vol. 6, no. 6, pp. 2773–2780, 2016.
- [26] P. Thakur and S. Dhiman, "An Efficient Image Segmentation Technique by

- Integrating FELICM with Negative Selection Algorithm,” *Int. J. Signal Process. Image Process. Pattern Recognit.*, vol. 8, no. 10, pp. 63–70, 2015.
- [27] M. Rizman, S. Mohd, S. H. Herman, and Z. Sharif, “Application of K-Means Clustering in Hot Spot Detection for Thermal Infrared Images,” pp. 107–110, 2017.
- [28] N. Dhanachandra, K. Manglem, and Y. J. Chanu, “Image Segmentation using K -means Clustering Algorithm and Subtractive Clustering Algorithm,” *Procedia - Procedia Comput. Sci.*, vol. 54, pp. 764–771, 2015.
- [29] S. Hadianti and D. Riana, “Segmentasi Citra Bemisia Tabaci Menggunakan Metode K-Means,” in *Seminar Nasional Inovasi dan Tren*, 2018, pp. A118–A123.
- [30] U. Dorj, M. Lee, and S. Yun, “An yield estimation in citrus orchards via fruit detection and counting using image processing,” *Comput. Electron. Agric.*, vol. 140, pp. 103–112, 2017.
- [31] E. Bostanci, N. Kanwal, B. Bostanci, and M. S. Guzel, “A Fuzzy Brute Force Matching Method for Binary Image Features,” vol. 1, pp. 1–5.
- [32] A. Rachmat and Y. Lukito, “SENTIPOL : Dataset Sentimen Komentar Pada Kampanye PEMILU Presiden Indonesia 2014 dari Facebook Page,” in *Konferensi Nasional Teknologi Informasi dan Komunikasi*, 2016, no. December.
- [33] Technopedia, “Training Dataset,” <https://www.techopedia.com/definition/33181/training-data>, 2020. .
- [34] A. Rohman, “Model Algoritma K-Nearest Neighbor (K-NN) Untuk Prediksi Kelulusan Mahasiswa,” *J. Ilm. Teknol.*, vol. 1, no. 1, 2015.
- [35] A. Latif, M. Yusof, S. S.N, and R. N, “Implementation of GLCM Features in Thermal Imaging for Human Affective State Detection,” in *IEEE International Symposium on Robotics and Intelligent Sensors*, 2015, vol. 76, pp. 308–315.
- [36] C. Malegori, L. Franzetti, R. Guidetti, E. Casiraghi, and R. Rossi, “GLCM , an image analysis technique for early detection of biofilm,” *J. Food Eng.*, vol. 185, pp. 48–55, 2016.

- [37] Y. W. Pamungkas and D. Q. Utama, “Klasifikasi Gambar Gigitan Ular Menggunakan Regionprops dan Algoritma Decision Tree,” vol. 1, pp. 69–76, 2020.
- [38] M. Widyaningsih, “Identifikasi Kematangan Buah Apel dengan Grayscale Level Co-Occurance Matrix (GLCM),” *J. Saintekom*, vol. 6, no. 114, 2016.
- [39] H. M. Quintero, H. M. Ariza, and J. R. Mozo, “Performance Analysis for Algorithms of Recognition of Geometric Patterns in Mechanical Pieces,” vol. 12, no. 23, pp. 13807–13811, 2017.
- [40] D. Abdullah and A. Purwanto, “Capturing ID Card Pada Video Live Berdasarkan Warna Menggunakan Metode Image Substraction dan Regionprops,” *Telematik*, vol. 7, no. 2, pp. 1638–1647, 2015.
- [41] M. Syahid, “Radial Basis Probabilistic Neural Networks for Swamp Rice Seed Morphology Identification in South Kalimantan,” vol. 4, pp. 14–21, 2015.
- [42] O. D. Nugraheni, I. W. Astika, and I. D. M. Subrata, “Palm Kernel Classification Based on Texture and Morphological Image Analysis Using K-Nearest Neighborhood (KNN),” *J. Keteknikan Pertan.*, vol. 5, pp. 113–120, 2017.
- [43] I. Aljarah, H. Saadeh, A. M. A. Hossam, F. Mohammad, and A. H. Seyedali, “Simultaneous Feature Selection and Support Vector Machine Optimization Using the Grasshopper Optimization Algorithm,” 2018.
- [44] J. Nayak, B. Naik, and H. S. Behera, “A Comprehensive Survey on Support Vector Machine in Data Mining Tasks : Applications & Challenges,” no. March 2017, 2015.
- [45] R. A. Fauzannissa, H. Yasin, and D. Ispriyanti, “Peramalan harga minyak mentah dunia menggunakan metode radial basis function neural network,” vol. 5, pp. 193–202, 2015.
- [46] Y. Andrian and E. Ningsih, “Prediksi Curah Hujan Di Kota Medan Menggunakan Metode Backpropogation Neural Network,” pp. 184–189, 2014.
- [47] S. Jane and A. Sunarauw, “Algoritma Pelatihan Levenberg-Marquardt

- Backpropagation Artificial Neural Network Untuk Data Time Series,” pp. 213–222, 2016.
- [48] M. Yusa *et al.*, “Evaluasi Model Decision Tree C4.5 Guna Prediksi,” pp. 147–152, 2015.
- [49] S. D. Fabiyi *et al.*, “Varietal Classification of Rice Seeds Using RGB and Hyperspectral Images,” pp. 22493–22505, 2020.
- [50] A. A. Nurcahyani and R. Saptono, “Identifikasi Kualitas Beras dengan Citra Digital,” vol. 2, no. 1, pp. 63–72, 2015.
- [51] T. N. Wah, P. E. San, T. Hlaing, and R. Sample, “Analysis on Feature Extraction and Classification of Rice Kernels for Myanmar Rice Using Image Processing Techniques,” vol. 8, no. 8, pp. 603–606, 2018.
- [52] V. S. Kolkure and M. B. N. Shaikh, “Identification And Quality Testing Of Rice Grains Using Image Processing And Neural network,” pp. 130–135, 2016.
- [53] N. Alfianika, *Buku Ajar Metode Penelitian Pengajaran Bahasa Indonesia*. Yogyakarta: Deepublish, 2018.
- [54] K. Dawk, D. Ngampak, and P. Piamsa-nga, “Image Analysis of Broken Rice Grains of,” pp. 115–120, 2015.
- [55] A. Gholamy and O. Kosheleva, “Why 70 / 30 or 80 / 20 Relation Between Training and Testing Sets : A Pedagogical Explanation,” 2018.
- [56] Y. Xie and D. Richmond, “Pre-training on Grayscale ImageNet Improves Medical Image Classification,” no. 2.
- [57] N. Bayramoglu, “Deep Learning for Magnification Independent Breast Cancer Histopathology Image Classification,” pp. 2440–2445, 2016.

DAFTAR RIWAYAT HIDUP

A. Biodata Mahasiswa

NIM : 14002295
Nama : Ridan Nurfalih
Tempat & Tanggal Lahir : Tasikmalaya, 13 Desember 1995
Jenis Kelamin : Laki-laki
Alamat Lengkap : Kp. Cideeng RT/RW 018/004 Ds. Sukasenang
Kec.Tanjungjaya Kab.Tasikmalaya Jawa Barat

B. Riwayat Pendidikan Formal dan Non-Formal

1. SDN Cideeng, lulus tahun 2008
2. SMP Nurul Huda, lulus tahun 2011
3. SMK AL Falah Tanjungjaya, lulus tahun 2014
4. AMIK BSI Tasikmalaya, 2017
5. Universitas BSI Bandung, 2018

C. Riwayat Pengalaman Organisasi dan Pekerjaan

1. OSIS SMK AL Falah Tanjungjaya 2013-2014
2. Pradana Pramuka SMK AL Falah Tanjungjaya 2013-2014
3. Ketua Rohis SMK AL Falah Tanjungjaya 2013-2014
4. Ketua English Club AMIK BSI Tasikmalaya, 2016-2017
5. Anggota Senat Mahasiswa AMIK BSI Tasikmalaya, 2016-2017
6. Anggota Tasik English Forum, 2016-2017
7. Staf Program Studi Sistem Informasi STMIK Nusa Mandiri, 2019-sekarang

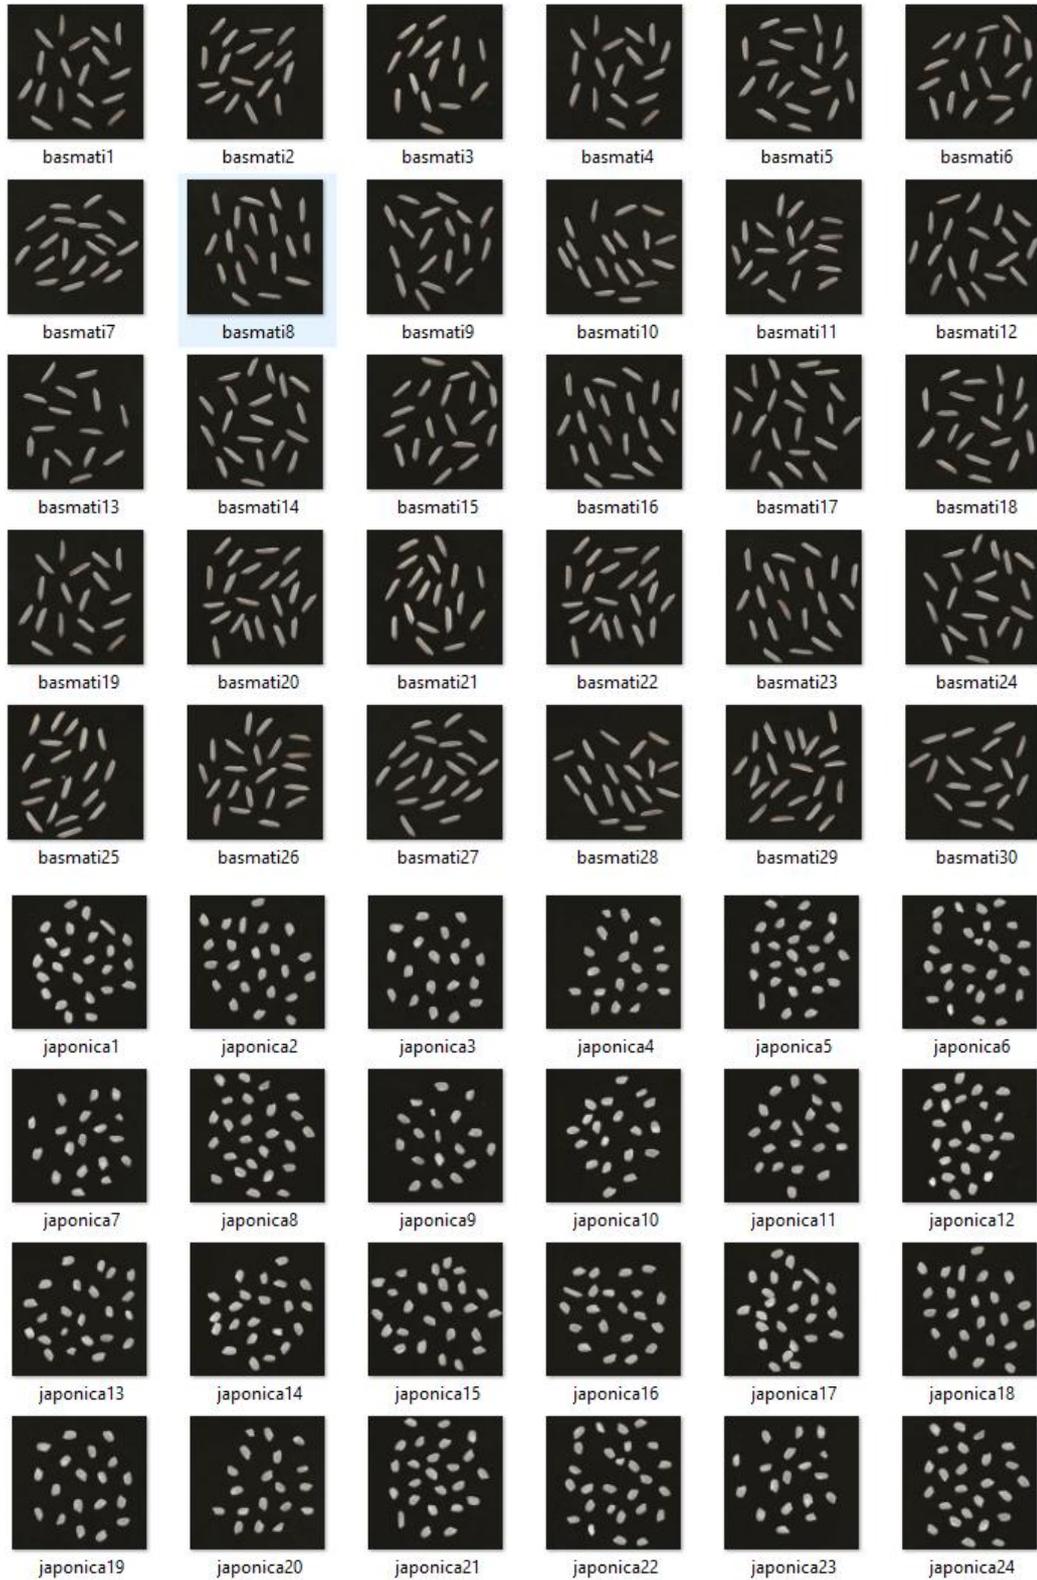


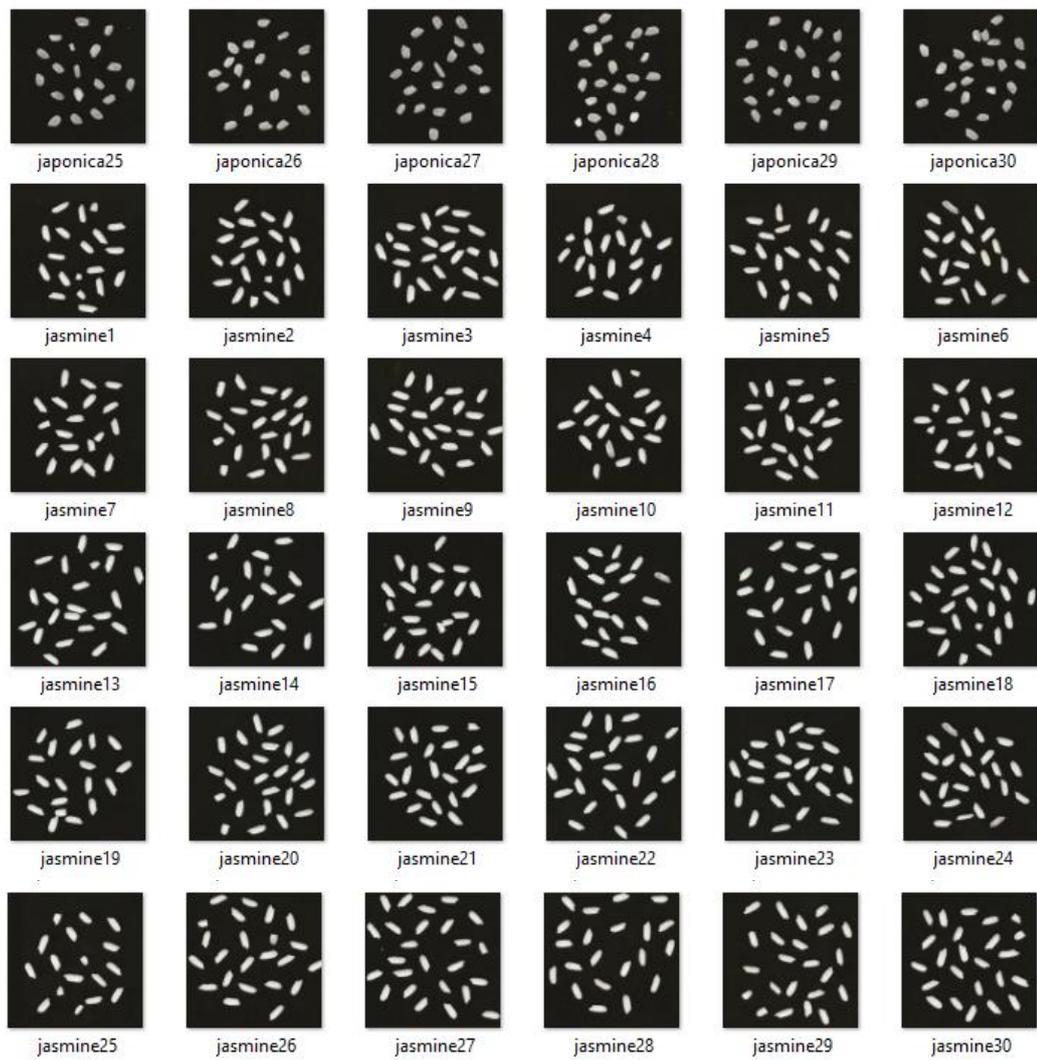
Jakarta, 4 Agustus 2020

Ridan Nurfalih

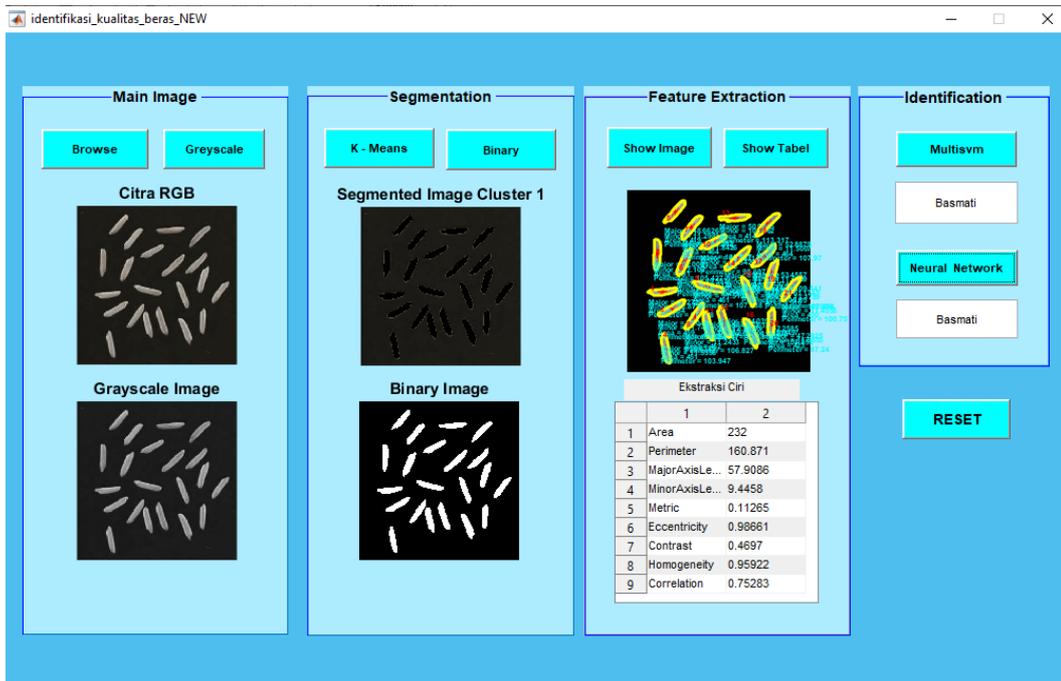
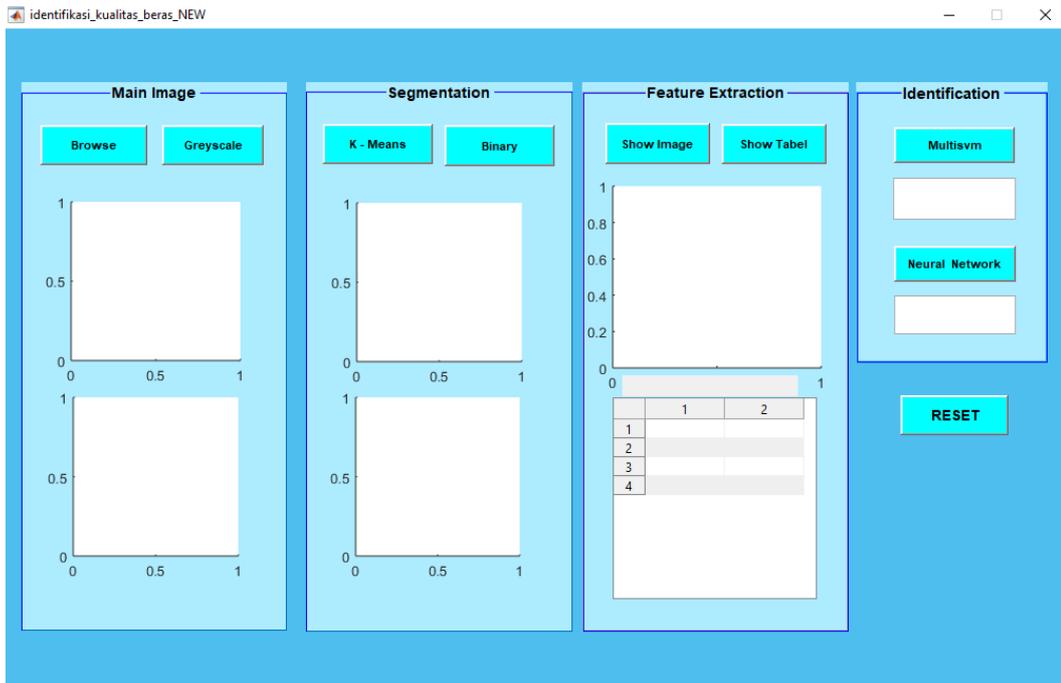
LAMPIRAN-LAMPIRAN

Lampiran 1 Dataset Citra Butir Beras





Lampiran 2 Tampilan Antar Muka GUI MATLAB



Lampiran 3 Coding Konversi RGB ke Grayscale

```
227 % --- Executes on button press in pushbutton5.
228 function pushbutton5_Callback(hObject, eventdata, handles)
229 % hObject handle to pushbutton5 (see GCBO)
230 % eventdata reserved - to be defined in a future version of MATLAB
231 % handles structure with handles and user data (see GUIDATA)
232 - Img = handles.Img;
233 - Gray = rgb2gray(Img);
234 - axes(handles.axes4)
235 - imshow(Gray)
236 - title('Grayscale Image');
237
238 - handles.gray = gray;
239 - guidata(hObject, handles)
240
```

Lampiran 4 Coding Segmentasi K-Means

```
273 - Img = handles.Img;
274 - cform = makecform('srgb2lab');
275 - lab = applycform(Img,cform);
276
277 - ab = double(lab(:,:,2:3));
278 - nrows = size(ab,1);
279 - ncols = size(ab,2);
280 - ab = reshape(ab,nrows*ncols,2);
281
282 - nColors = 2;
283 - [cluster_idx, ~] = kmeans(ab,nColors,'distance','sqEuclidean', ...
284     'Replicates',3);
285
286 - pixel_labels = reshape(cluster_idx,nrows,ncols);
287
288 - segmented_images = cell(1,3);
289 - rgb_label = repmat(pixel_labels,[1 1 3]);
290
291 %segmentasi k-means
292 - for k = 1:nColors
293 -     color = Img;
294 -     color(rgb_label ~= k) = 0;
295 -     segmented_images{k} = color;
296 - end
297
298 - area_cluster1 = sum(find(pixel_labels==1));
299 - area_cluster2 = sum(find(pixel_labels==2));
300
301 - [~,cluster_min] = min([area_cluster1,area_cluster2]);
302
303 - Img_bw = (pixel_labels==cluster_min);
304 - Img_bw = imfill(Img_bw,'holes');
305 - Img_bw = bwareaopen(Img_bw,50);
306
```

Lampiran 5 Coding Konversi Biner

```
247
248 -   Img = handles.Img;
249 -   Img_reg2 = handles.Img_reg2
250 -   Gray = rgb2gray(Img_reg2);
251 -   thresh = graythresh(Gray);
252 -   bw = im2bw(Gray,thresh);
253
```

Lampiran 6 Coding Ekstraksi Fitur (Tampil Gambar)

```
560 -   I = Img_reg2;
561 -   bw = im2bw(I, graythresh(I));
562 -   bw2 = imfill(bw, 'holes');
563
564 -   s = regionprops(bw2, 'centroid', 'Area', 'Perimeter', 'MajorAxisLength', 'MinorAxisLength', 'Eccentricity');
565 -   centroids = cat(1, s.Centroid);
566 -   area = cat(1, s.Area);
567 -   perimeter = cat(1, s.Perimeter);
568 -   MajorAxisLength = cat(1, s.MajorAxisLength);
569 -   MinorAxisLength = cat(1, s.MinorAxisLength);
570 -   Eccentricity = cat(1, s.Eccentricity);
571 -   hold on
572 -   plot(centroids(:,1), centroids(:,2), 'r*')
573
574 -   [B, L] = bwboundaries(bw2, 'noholes');
575 -   [~, num] = bwlabel(bw2, 8);
576
577 -   for k = 1:num
578 -       boundary = B(k);
579 -       plot(boundary(:,2), boundary(:,1), 'y', 'LineWidth', 2)
580 -       text(boundary(1,2), boundary(1,1)-7, strcat([' ', num2str(k)]), 'Color', 'r', ...
581 -           'FontSize', 5, 'FontWeight', 'bold');
582 -       text(boundary(1,2), boundary(1,1)+14, strcat(['Major = ', num2str(MajorAxisLength(k))]), 'Color', 'c', ...
583 -           'FontSize', 5, 'FontWeight', 'bold');
584 -       text(boundary(1,2), boundary(1,1)+21, strcat(['Minor = ', num2str(MinorAxisLength(k))]), 'Color', 'c', ...
585 -           'FontSize', 5, 'FontWeight', 'bold');
586 -       text(boundary(1,2), boundary(1,1)+28, strcat(['Area = ', num2str(area(k))]), 'Color', 'c', ...
587 -           'FontSize', 5, 'FontWeight', 'bold');
588 -       text(boundary(1,2), boundary(1,1)+35, strcat(['Perimeter = ', num2str(perimeter(k))]), 'Color', 'c', ...
589 -           'FontSize', 5, 'FontWeight', 'bold');
590 -   end
591
592 -   hold off
593
```

Lampiran 7 Coding Ekstraksi Fitur (Tampil Tabel)

```
307 - stats = regionprops(Img_bw, 'Area', 'Perimeter', 'MajorAxisLength', 'MinorAxisLength', 'Eccentricity');
308 -     area = stats.Area;
309 -     perimeter = stats.Perimeter;
310 -     majoraxislength = stats.MajorAxisLength;
311 -     minoraxislength = stats.MinorAxisLength;
312 -     metric = 4*pi*area/(perimeter^2);
313 -     eccentricity = stats.Eccentricity;
314 -
315 -     Img_gray = rgb2gray(Img);
316 -     Img_gray(~Img_bw) = 0;
317 -
318 -
319 - pixel_dist = 1;
320 - GLCM = graycomatrix(Img_gray, 'Offset', [0 pixel_dist; -pixel_dist pixel_dist; -pixel_dist 0; -pixel_dist -pixel_dist]);
321 - stats = graycoprops(GLCM, {'contrast', 'correlation', 'energy', 'homogeneity'});
322 - Contrast = mean(stats.Contrast);
323 - Correlation = mean(stats.Correlation);
324 - Energy = mean(stats.Energy);
325 - Homogeneity = mean(stats.Homogeneity);
326 -
327 - data_uji = [area, perimeter, majoraxislength, minoraxislength, metric, eccentricity, Contrast, Homogeneity, Correlation];
328 -
329 - data_uji = [area, perimeter, majoraxislength, minoraxislength, metric, eccentricity, Contrast, Homogeneity, Correlation];
330 -
331 - ciri_total = cell(9,2);
332 - ciri_total(1,1) = 'Area';
333 - ciri_total(2,1) = 'Perimeter';
334 - ciri_total(3,1) = 'MajorAxisLength';
335 - ciri_total(4,1) = 'MinorAxisLength';
336 - ciri_total(5,1) = 'Metric';
337 - ciri_total(6,1) = 'Eccentricity';
338 - ciri_total(7,1) = 'Contrast';
339 - ciri_total(8,1) = 'Homogeneity';
340 - ciri_total(9,1) = 'Correlation';
341 - ciri_total(1,2) = num2str(area);
342 - ciri_total(2,2) = num2str(perimeter);
343 - ciri_total(3,2) = num2str(majoraxislength);
344 - ciri_total(4,2) = num2str(minoraxislength);
345 - ciri_total(5,2) = num2str(metric);
346 - ciri_total(6,2) = num2str(eccentricity);
347 - ciri_total(7,2) = num2str(Contrast);
348 - ciri_total(8,2) = num2str(Homogeneity);
349 - ciri_total(9,2) = num2str(Correlation);
350 -
351 - handles.ciri_total = ciri_total;
352 - guidata(hObject, handles)
353 -
354 - set(handles.text2, 'String', 'Ekstraksi Ciri')
355 - set(handles.uitable1, 'Data', ciri_total, 'RowName', 1:9)
356 - handles.data_uji = data_uji;
357 - guidata(hObject, handles)
```

Lampiran 8 Coding Multi-SVM

```
397 % --- Executes on button press in pushbutton9.
398 function pushbutton9_Callback(hObject, eventdata, handles)
399 % memanggil variabel data_uji yang ada pada lokasi handles
400 data_uji = handles.data_uji;
401
402 % load data_latih dan target_latih hasil pelatihan
403 load latih_database50
404 load target_latih
405
406 % pengujian menggunakan algoritma multisvm
407 output = multisvm(latih_database50,target_latih,data_uji);
408
409 % mengubah nilai keluaran menjadi kelas keluaran
410 switch output
411     case 1
412         jenis_beras = 'Basmati';
413     case 2
414         jenis_beras = 'Japonica';
415     case 3
416         jenis_beras = 'Jasmine';
417     otherwise
418         jenis_beras = 'tidak dikenali';
419 end
420
421 % menampilkan hasil identifikasi jenis bunga pada edit text
422 set(handles.edit2,'String',jenis_beras)
423 % hObject handle to pushbutton9 (see GCBO)
```

Lampiran 9 Coding Neural Network

```
502 pixel_dist = 1;
503 GLCM = graycomatrix(Img_gray,'Offset',[0 pixel_dist; -pixel_dist pixel_dist; -pixel_dist 0; -pixel_dist -pixel_dist]);
504 stats = graycoprops(GLCM,{'contrast','correlation','energy','homogeneity'});
505 Contrast = mean(stats.Contrast);
506 Correlation = mean(stats.Correlation);
507 Energy = mean(stats.Energy);
508 Homogeneity = mean(stats.Homogeneity);
509
510 data_uji = [area,perimeter,majoraxislength,minoraxislength,metric,eccentricity,Contrast,Homogeneity,Correlation];
511 input = [area;perimeter;majoraxislength;minoraxislength;metric;eccentricity;Contrast;Homogeneity;Correlation];
512 load net
513 output = round(sim(net,input));
514
515 if output == 1
516     kelas = 'Basmati';
517 elseif output == 2
518     kelas = 'Japonica';
519 elseif output == 3
520     kelas = 'Jasmine';
521 end
522
523 set(handles.edit3,'String',kelas)
524
```