

**IDENTIFIKASI MUTU JAGUNG MENGGUNAKAN
FITUR WARNA DAN TEKSTUR BERBASIS PENGOLAHAN
CITRA DIGITAL DAN ALGORITMA *K-NEAREST NEIGHBOR*
(K-NN)**

SKRIPSI

Oleh:
MIFTAHUL JANNAH
135100300111012



**JURUSAN TEKNOLOGI INDUSTRI PERTANIAN
FAKULTAS TEKNOLOGI PERTANIAN
UNIVERSITAS BRAWIJAYA
MALANG
2018**

**IDENTIFIKASI MUTU JAGUNG MENGGUNAKAN
FITUR WARNA DAN TEKSTUR BERBASIS PENGOLAHAN
CITRA DIGITAL DAN ALGORITMA *K-NEAREST NEIGHBOR*
(K-NN)**

Oleh:
MIFTAHUL JANNAH
135100300111012

**Sebagai salah satu syarat untuk memperoleh
Gelar Sarjana Teknik**



**JURUSAN TEKNOLOGI INDUSTRI PERTANIAN
FAKULTAS TEKNOLOGI PERTANIAN
UNIVERSITAS BRAWIJAYA
MALANG
2018**

LEMBAR PERSETUJUAN

Judul TA : Identifikasi Mutu Jagung Menggunakan Fitur Warna dan
Tekstur Berbasis Pengolahan Citra Digital dan Algoritma
K-Nearest Neighbor (K-NN)

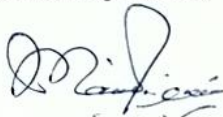
Nama Mahasiswa : Miftahul Jannah

NIM : 135100300111012

Jurusan : Teknologi Industri Pertanian

Fakultas : Teknologi Pertanian

Pembimbing Pertama,



Mas'ud Effendi, STP., MP.

NIP 19800823 200501 1 003

Tanggal Persetujuan:

.....

Pembimbing Kedua,



Ir. Usman Effendi, MS.

NIP 19610727 198701 1 001

Tanggal Persetujuan:

.....

LEMBAR PENGESAHAN

Judul TA : Identifikasi Mutu Jagung Menggunakan Fitur Warna dan
Tekstur Berbasis Pengolahan Citra Digital dan Algoritma
K-Nearest Neighbor (K-NN)

Nama Mahasiswa : Miftahul Jannah

NIM : 135100300111012

Jurusan : Teknologi Industri Pertanian

Fakultas : Teknologi Pertanian

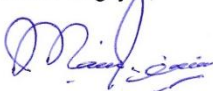
Dosen Penguji I,



Dr. Sucipto STP., MP.

NIP. 19730602 199903 1 001

Dosen Penguji II,



Mas'ud Effendi, STP., MP.

NIP 19800823 200501 1 003

Dosen Penguji III,



Ir. Usman Effendi, MS.

NIP 19610727 198701 1 001



Tanggal Lulus TA :

RIWAYAT HIDUP



Penulis dilahirkan di Tuban pada tanggal 09 April 1995 dari Ayah yang bernama Suparno dan Ibu Kurtitik. Penulis menyelesaikan pendidikan Sekolah Dasar di SDN Ngampel Bancar pada tahun 2007, kemudian melanjutkan ke Sekolah Menengah Tingkat Pertama di SMPN 2 Bancar dengan tahun kelulusan 2010, dan menyelesaikan Sekolah Menengah Umum di SMA N 1 Tambakboyo pada tahun 2013.

Pada tahun 2018 penulis telah berhasil menyelesaikan pendidikannya di Universitas Brawijaya Malang di Jurusan Teknologi Industri Pertanian Fakultas Teknologi Pertanian. Pada masa pendidikannya, penulis aktif di beberapa kegiatan kepanitiaan serta pernah menjadi finalis pendanaan PKM-KC Kemenristekdikti tahun 2014. Penulis melaksanakan Praktek Kerja lapang di PT Wilmar Nabati Indonesia Gresik pada tahun 2016. Penulis pernah mengikuti *training* Sistem Manajemen Laboratorium ISO 17025 (Departemen *Quality Control* PT Wilmar Nabati Indonesia Gresik) pada tahun 2016, Sistem Manajemen Mutu ISO 9001 dan Sistem Manajemen K3 pada tahun 2017.



Alhamdulillah..... terima kasih Ya Allah
Karya kecil ini aku persembahkan kepada kedua
Orang Tuaku dan Sahabat-sahabatku tercinta, serta Orang-
orang yang selalu mendukung & mendo'akan
kebaikan untukku.....

PERNYATAAN KEASLIAN TA

Yang bertanda tangan di bawah ini :

Nama Mahasiswa : Miftahul Jannah
NIM : 135100300111012
Jurusan : Teknologi Industri Pertanian
Fakultas : Teknologi Pertanian
Judul TA : Identifikasi Mutu Jagung Menggunakan
Fitur Warna dan Tekstur Berbasis
Pengolahan Citra Digital dan Algoritma
K-Nearest Neighbor (K-NN)

Menyatakan bahwa,

TA dengan judul diatas merupakan karya asli penulis tersebut di atas. Apabila di kemudian hari terbukti pernyataan ini tidak benar, saya bersedia dituntut sesuai hukum yang berlaku.

Malang, 19 April 2018
Pembuat Pernyataan,

Miftahul Jannah
NIM 135100300111012

MIFTAHUL JANNAH. 135100300111012. Identifikasi Mutu Jagung Menggunakan Fitur Warna dan Tekstur Berbasis Pengolahan Citra Digital dan Algoritma *K-Nearest Neighbor* (K-NN). TA. Pembimbing: Mas'ud Effendi, STP. MP dan Ir. Usman Effendi, MS.

RINGKASAN

Jagung merupakan komoditas tanaman pangan yang sebagian besar dimanfaatkan sebagai bahan baku pakan. Permasalahan saat ini, mutu jagung petani memiliki kadar air tinggi. Untuk pemenuhan jagung lokal, perusahaan harus memasok melalui pedagang. Penentuan mutu jagung di tingkat petani didasarkan pada lama pengeringan yang dapat mempengaruhi harga beli jagung. Metode ini memiliki kelemahan yaitu rendahnya efisiensi, objektivitas dan tingkat konsistensi serta dapat menimbulkan konflik antara pedagang dan petani. Karenanya, diperlukan metode identifikasi mutu jagung yang baik dan akurat berbasis pengolahan citra digital. Kemampuan pengolahan citra digital yang canggih memungkinkan proses identifikasi mutu komoditas pertanian menjadi lebih efektif dan efisien. Tujuan penelitian ini untuk merancang sistem identifikasi mutu dan varietas jagung berdasarkan fitur warna dan tekstur serta menentukan tingkat akurasi metode *K-Nearest Neighbor* (K-NN) dalam menduga mutu jagung di tingkat petani.

Pada penelitian ini, standar mutu jagung didasarkan PERMENDAGRI No.27/M-DAG/PER/5/2017 tentang penetapan harga acuan pembelian jagung di petani. Varietas jagung yang digunakan yaitu Pertiwi-3 (P-3) dan Pertiwi-6 (P-6). Sistem identifikasi mutu jagung dirancang menggunakan input 7 fitur (*H, S, V, contrast, correlation, energy, homogeneity*) dan algoritma K-NN sebagai *classifiers*. Sistem ini mengklasifikasikan mutu jagung ke dalam 10 kategori mutu, yakni Kategori 1 (P-3 maks kadar air 15%), Kategori 2 (P-3 maks kadar air 20%), Kategori 3 (P-3 maks kadar air 25%), Kategori 4 (P-3 maks kadar air 30%), Kategori 5 (P-3 maks kadar air 35%), Kategori 6 (P-6 maks kadar air 15%), Kategori 7

(P-6 maks kadar air 20%), Kategori 8 (P-6 maks kadar air 25%), Kategori 9 (P-6 maks kadar air 30%), dan Kategori 10 (P-6 maks kadar air 35%). Hasil keluaran sistem berupa varietas, kadar air serta harga jagung.

Berdasarkan hasil penelitian yang dilakukan, rasio pengujian yang digunakan 70%:30%, jumlah data latih yang digunakan sebanyak 350 citra dan data uji sebanyak 150 citra. Hasil penelitian menggunakan variasi nilai k (tetangga terdekat) 1,3,5,7,9 serta metode jarak perhitungan *euclidean* dan *Cityblock* menunjukkan bahwa sistem mampu mengidentifikasi mutu dan varietas jagung dengan baik. Akurasi tertinggi diperoleh saat nilai $k=5$ menggunakan *Cityblock distance* sebesar 90,00%.

Kata kunci: harga jagung, K-NN, pengolahan citra digital, warna dan tekstur

MIFTAHUL JANNAH. 135100300111012. Identification of Corn Quality using Color and Texture Features based on Digital Image Processing and K-Nearest Neighbor (K-NN) Algorithm. Minor Thesis. Supervisor: Mas'ud Effendi, STP. MP. Co-Supervisor: Ir. Usman Effendi, MS.

SUMMARY

Corn is a food commodity that most widely used for feed raw material. The current issues, the quality of corn at the farmers has high moisture content. Thus, feed industry should supply through wholesalers to absorb local corn. Quality determination for corn at farm-level based on drying time may affect the purchase price of corn. This method has disadvantages include low efficiency, objectivity, consistency and even remains a problem between the wholesaler and the farmer. Therefore, a good and accurate method for corn quality identification based digital image processing is required. Sophistication of digital image processing allow the quality identification process of agricultural commodities be more effective and efficient. This research aimed at designing an identification system of corn quality and varieties based on color and texture features, also determining the accuracy level of K-Nearest Neighbor (K-NN) for estimating quality of corn at farm-level.

In this study, the quality standard of corn used under the Ministerial Regulation No. 27/M-DAG/PER/5/2017 on purchase price determination for corn at farm-level. Corn varieties used such as Pertiwi-3 (P-3) and Pertiwi-6 (P-6). Corn quality identification system designed with 7 features input (H,S,V, contrast, correlation, energy, homogeneity) and K-NN algorithm as classifiers. This system classify corn into 10 quality categories, namely Category 1 (P-3 moisture max 15%), Category 2 (P-3 moisture max 20%), Category 3 (P-3 moisture max 25%), Category 4 (P-3 moisture max 30%), Category 5 (P-3 moisture max 35%), Category 6 (P-6 moisture max 15%), Category 7 (P-6 moisture max 20%), Category 8 (P-6 moisture max 25%), Category 9 (P-6 moisture max 30%), and Category

10 (P-6 moisture max 35%). Output of the system include category of corn quality, moisture content, varieties and purchase price of corn.

Based on this study using testing ratio 70%:30%, there are 350 total dataset used for training and 150 images used for testing set. The results using variation value of k (nearest neighbor) 1,3,5,7,9 with euclidean and cityblock distance method show that system is able to identify quality and varieties of corn well. The highest accuracy obtained when $k=5$ using Cityblock distance equal to 90,00%.

Keywords: color and texture, corn price, digital image processing, K-NN,

KATA PENGANTAR

Segala puji bagi Allah SWT, karena berkat, rahmat dan anugerah-Nya, penulis dapat menyelesaikan laporan Tugas Akhir dengan baik. Tugas Akhir berjudul “Identifikasi Mutu Jagung Menggunakan Fitur Warna dan Tekstur Berbasis Pengolahan Citra Digital dan Algoritma *K-Nearest Neighbor (K-NN)*”. Penyusunan Tugas Akhir ini merupakan salah satu syarat untuk mencapai gelar Sarjana Teknik.

Pada kesempatan ini, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Mas’ud Effendi, STP., MP selaku dosen pembimbing pertama Tugas Akhir yang telah membimbing dan memberikan arahan, bimbingan, serta ilmu pengetahuan kepada penulis
2. Bapak Ir. Usman Effendi, MS selaku dosen pembimbing kedua Tugas Akhir yang telah membimbing penulis serta memberikan arahan dan ilmu kepada penulis
3. Bapak Dr. Sucipto, STP. MP selaku Dosen Penguji yang telah memberikan arahan, saran, serta masukan kepada penulis
4. Kedua Orang tua yang selalu mendo’akan dan telah banyak memberi dukungan moril serta kerabat dekat yang senantiasa memberikan dorongan kepada penulis
5. Andriyani Wahyu Utami yang merupakan teman, sahabat dan rekan dalam hal apapun yang sama-sama berjuang dalam dunia *per-codingan* untuk menyelesaikan Tugas Akhir
6. Dwi Ariyani, Eky Kartiani, Fathimah Azzahra, Gabrile Hardiani, Kartika Dwi Ulfiyanti dan Syafirah Husna Trisna Putri (119 *Squad*) yang selalu ada menghibur, mendengarkan keluh kesah penulis dan selalu menjadi alarm motivasi penulis untuk menyelesaikan Tugas Akhir
7. Teman-teman satu bimbingan yang telah sama-sama berjuang dan saling mendukung satu sama lain
8. Teman-teman Teknologi Industri Pertanian 2013 yang telah memberikan semangat dan dukungan satu sama lain

9. Semua pihak yang telah membantu penulis dalam menyelesaikan laporan skripsi ini dalam bentuk apapun yang tidak dapat penulis sebutkan satu persatu

Penulis menyadari keterbatasan pengetahuan, referensi dan pengalaman dalam penyusunan Tugas Akhir ini. Karenanya, kritik dan saran sangat dibutuhkan agar laporan ini lebih baik. Harapan penulis semoga Tugas Akhir ini dapat memberikan manfaat bagi penulis maupun semua pihak yang membutuhkan.

Malang, 15 Februari 2018
Penulis,

Miftahul Jannah

DAFTAR ISI

HALAMAN JUDUL TA	i
HALAMAN PERSETUJUAN	ii
HALAMAN PENGESAHAN	iii
RIWAYAT HIDUP	iv
HALAMAN PERUNTUKAN	v
PERNYATAAN KEASLIAN TA	vi
RINGKASAN	vii
SUMMARY	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR TABEL	xvii
DAFTAR GAMBAR	xix
DAFTAR LAMPIRAN	xxi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
BAB II TINJAUAN PUSTAKA	
2.1 Jagung	5
2.1.1 Jenis-jenis jagung	6
2.1.2 Mutu Jagung	7
2.2 Citra Digital	9
2.2.1 Citra biner	10
2.2.2 Citra <i>grayscale</i>	11
2.2.3 Citra warna RGB (<i>Red, Green, Blue</i>)	12
2.2.4 Citra warna HSV (<i>Hue, Saturation, Value</i>)	13
2.3 Pengolahan Citra Digital	15
2.3.1 Akuisisi citra (<i>images acquisition</i>)	16
2.3.2 Pengolahan citra tingkat awal (<i>image preprocessing</i>)	16
2.3.3 Segmentasi citra (<i>image segmentation</i>)	16
2.3.4 Ekstraksi fitur (<i>feature extraction</i>)	18

2.3.5 Pengenalan dan interpretasi (<i>recognition and interpretation</i>).....	18
2.4 Analisis Tekstur	18
2.4.1 <i>Gray Level Co-occurrence Matrix</i>	19
2.5 Algoritma <i>K-Nearest Neighbor</i>	22
2.5.1 Tahapan klasifikasi KNN	23
2.5.2 Metode perhitungan jarak	24
2.6 Penelitian Terdahulu	25
BAB III METODE PENELITIAN.....	27
3.1 Waktu dan Tempat Pelaksanaan	27
3.2 Bahan dan Alat	27
3.3 Batasan Masalah	27
3.4 Pelaksanaan Penelitian.....	28
3.4.1 Identifikasi masalah	29
3.4.2 Studi literatur	29
3.4.3 Pengumpulan data	29
3.4.4 Persiapan sampel.....	29
3.4.5 Perancangan perangkat pengambilan citra	31
3.4.6 Pengembangan algoritma pengolahan citra	33
3.4.7 Perancangan GUI (antarmuka sistem).....	36
3.4.8 Pelatihan dan Pengujian sistem	37
3.4.9 Perhitungan akurasi sistem	38
3.4.10 Kesimpulan dan saran	39
BAB IV HASIL DAN PEMBAHASAN.....	41
4.1 Implementasi Perangkat Pengambilan Citra	41
4.2 Pengembangan Algoritma Pengolahan Citra	42
4.2.1 Pembacaan <i>image</i> dan <i>resizing image</i>	43
4.2.2 Ekstraksi fitur.....	44
4.2.3 Klasifikasi algoritma K-NN	46
4.3 Implementasi GUI (Antarmuka Sistem)	49
4.4 Pelatihan dan Pengujian sistem	54
4.5 Perhitungan Akurasi sistem	59
BAB V KESIMPULAN DAN SARAN.....	61
5.1 Kesimpulan	61
5.2 Saran	61

DAFTAR PUSTAKA..... 63
LAMPIRAN..... 73





DAFTAR TABEL

Tabel 2.1	Standar mutu jagung berdasarkan SNI 4483-2013	8
Tabel 2.2	Definisi fisik biji jagung menurut SNI 4483-2013	8
Tabel 2.3	Syarat mutu sebagai acuan harga pembelian jagung di tingkat petani.....	9
Tabel 4.1	Contoh nilai fitur data uji	46
Tabel 4.2	Hasil klasifikasi benar menggunakan <i>K-Nearest Neighbor</i>	56



DAFTAR GAMBAR

Gambar 2.1	Jagung kuning.....	5
Gambar 2.2	(a) Varietas Pertiwi 3, (b) Varietas Pertiwi 6	7
Gambar 2.3	Koordinat citra digital.....	10
Gambar 2.4	Citra biner	11
Gambar 2.5	Citra <i>grayscale</i>	12
Gambar 2.6	Citra warna RGB	12
Gambar 2.7	Model warna RGB.....	13
Gambar 2.8	Model warna HSV	14
Gambar 2.9	Tahapan pengolahan citra digital.....	15
Gambar 2.10	Teknik segmentasi	17
Gambar 2.11	Hubungan ketetangaan antar piksel sebagai fungsi orientasi dan jarak spasial	20
Gambar 2.12	Perhitungan GLCM.....	21
Gambar 2.13	Klasifikasi KNN.....	23
Gambar 3.1	Tahapan penelitian.....	28
Gambar 3.2	Perangkat pengambilan citra	31
Gambar 3.3	Tahapan pengembangan algoritma pengolahan citra.....	33
Gambar 3.4	K-NN dengan nilai k tetangga.....	35
Gambar 3.5	Struktur antarmuka sistem.....	37
Gambar 3.6	Tahapan analisis citra	38
Gambar 4.1	Ilustrasi pengambilan citra.....	42
Gambar 4.2	(a) Citra sebelum <i>cropping</i> , (b) Citra hasil <i>cropping</i> , (c) Citra hasil <i>resizing</i>	43
Gambar 4.3	(a) Ekstraksi nilai <i>hue</i> , (b) Ekstraksi nilai <i>saturation</i> , (c) Ekstraksi nilai <i>value</i>	44
Gambar 4.4	(a) Citra biner, (b) Citra RGB hasil segmentasi, (c) Citra <i>grayscale</i>	45
Gambar 4.5	Ilustrasi hasil klasifikasi K-NN menggunakan K=9 pada fitur <i>Mean Hue</i> dan <i>Homogeneity</i>	47
Gambar 4.6	Beranda aplikasi.....	50
Gambar 4.7	Isi menu file pada beranda aplikasi	50
Gambar 4.8	Isi menu about pada beranda aplikasi	50
Gambar 4.9	Kotak dialog keluar beranda aplikasi	51
Gambar 4.10	Tampilan identifikasi mutu jagung (<i>end user</i>).....	51

Gambar 4.11	Tampilan detail proses identifikasi	52
Gambar 4.12	Tampilan pengambilan citra uji	53
Gambar 4.13	Tampilan menu help	53
Gambar 4.14	(a) Tampilan tentang mutu jagung, (b) Tampilan tentang aplikasi	54
Gambar 4.15	Contoh tampilan hasil identifikasi mutu jagung (<i>end user</i>).....	57
Gambar 4.16	Contoh tampilan hasil detail proses identifikasi	58
Gambar 4.17	Perbandingan tingkat akurasi pada variasi nilai k dan <i>distance</i>	59

DAFTAR LAMPIRAN

Lampiran 1	Citra jagung	75
Lampiran 2	<i>Source code</i> ekstraksi fitur warna HSV dan fitur tekstur GLCM.....	79
Lampiran 3	Nilai ekstraksi fitur warna HSV dan fitur tekstur GLCM.....	81
Lampiran 4	Proyeksi data latih dalam ruang 7 dimensi	95
Lampiran 5	Contoh visualisasi K-NN menggunakan $k=9$ dan <i>Euclidean</i>	97
Lampiran 6	Hasil perhitungan jarak menggunakan <i>Euclidean distance</i>	99
Lampiran 7	Hasil perhitungan jarak menggunakan <i>Cityblock distance</i>	101
Lampiran 8	Penentuan k tetangga terdekat	103
Lampiran 9	Penentuan kelas berdasarkan label mayoritas	113
Lampiran 10	Tampilan menu <i>help</i> pada aplikasi Identifikasi mutu jagung	115
Lampiran 11	<i>Source code</i> proses pelatihan dan pengujian sistem.....	119
Lampiran 12	Hasil proses klasifikasi mutu jagung	123
Lampiran 13	Hasil akurasi terbaik klasifikasi mutu jagung menggunakan variasi nilai $k = 5$ dan metode jarak <i>Cityblock</i>	129

BAB I

PENDAHULUAN

1.1 Latar Belakang

Jagung merupakan komoditas tanaman pangan yang memiliki peran strategis dalam ketahanan pangan dan pertumbuhan ekonomi nasional. Selain perannya sebagai sumber pangan bagi sebagian masyarakat Indonesia, jagung juga digunakan sebagai bahan baku pakan ternak dan industri lain. Data Pusdatin (2016) menyebutkan jumlah produksi jagung periode 2011-2015 mengalami pertumbuhan positif dengan rata-rata pertumbuhan sebesar 5,89% per tahun, dimana kontribusi terbesar produksi jagung nasional menurut BPS (2016) berasal dari Provinsi Jawa Timur yaitu 32,06% dengan produksi terbesar kabupaten Tuban sebesar 8,3%. Pada periode yang sama, jumlah konsumsi rumah tangga nasional jagung menunjukkan kecenderungan fluktuatif tetapi rata-rata meningkat 1,02% per tahun, sedang total konsumsi jagung untuk industri rata-rata meningkat lebih tinggi yaitu sebesar 3,33% per tahun.

Permintaan jagung untuk industri pangan, pakan, dan kebutuhan industri lain dalam lima tahun ke depan diproyeksikan oleh Ditjen Tanaman Pangan (2016) terus mengalami peningkatan khususnya penggunaan jagung untuk bahan pakan meningkat lebih dari 60% total kebutuhan nasional. Badan Litbang Pertanian (2015) menyebutkan bahwa pemanfaatan jagung tertinggi digunakan sebagai pakan ternak yaitu 22% pakan ternak langsung dan 44% bahan baku industri pakan, 25% bahan baku industri pangan dan 9% konsumsi rumah tangga secara langsung. Untuk memenuhi kebutuhan jagung tersebut, aspek mutu menjadi sangat penting yang harus diperhatikan selain aspek kuantitas karena mutu jagung sebagai bahan baku menentukan mutu produk akhir dari industri.

Permasalahan mutu jagung saat ini yaitu masih tingginya tingkat kerusakan dan cemaran yang terjadi selama proses penanganan pascapanen maupun saat proses pemipilan dengan mesin. Hal ini mengakibatkan biji banyak yang rusak

dan rentan terhadap kontaminasi kapang yang dapat mencemari jagung (Somantri dan Miskiyah, 2012). Besarnya kehilangan dan kerusakan fisik biji jagung setelah pemanenan sampai penyimpanan berkisar 8,6 - 20,2% yang disebabkan oleh serangan serangga, jamur, tikus, kondisi awal penyimpanan, cara dan alat penyimpanan serta faktor lingkungan, sehingga banyak produk jagung di tingkat petani yang tidak terserap industri, khususnya industri pakan (BPTP, 2009).

Rendahnya mutu jagung di tingkat petani sebagian besar disebabkan kadar air jagung masih tinggi dan faktor lain dipengaruhi oleh kerusakan biji dan cemaran aflatoksin. Industri pakan tidak bisa memasok langsung dari petani jagung karena kadar air jagung yang dihasilkan terlampau jauh dari standar yang ditetapkan SNI, sehingga untuk menyerap jagung lokal, perusahaan harus memasok melalui pedagang pengepul hingga pedagang besar. Kondisi inilah yang menyebabkan harga beli jagung menjadi tinggi di tingkat konsumen (pedagang) dan rendah di tingkat produsen (petani). Ketidakstabilan harga jagung di tingkat petani terjadi karena pihak ketiga berperan dalam menentukan harga. Karenanya, Mendag membuat kebijakan harga jagung untuk menjaga stabilitas harga jagung di tingkat petani dan konsumen. Standar mutu jagung sebagai acuan penentuan harga di tingkat petani sesuai Peraturan Menteri Perdagangan RI No.27/M-DAG/PER/5/2017 dikategorikan menjadi lima kategori yaitu Kategori 1 kadar air maks 15%, Kategori 2 kadar air maks 20%, Kategori 3 kadar air maks 25%, Kategori 4 kadar air maks 30%, dan Kategori 5 kadar air maks 35%.

Pada prakteknya, pembelian jagung ditingkat petani oleh pedagang tidak sepenuhnya sesuai dengan harga ketetapan Mendag. Hal ini karena pedagang menentukan mutu jagung petani berdasarkan lama proses pengeringan, sehingga mempengaruhi keputusan harga beli. Penentuan mutu jagung dengan cara seperti ini memiliki beberapa kelemahan yaitu rendahnya efisiensi, objektivitas dan tingkat konsistensi serta dapat menimbulkan konflik antara pedagang dan petani. Oleh karena itu, untuk menghindari perbedaan penentuan mutu dan harga antar pedagang, maka perlu dilakukan pengembangan

metode identifikasi mutu jagung di tingkat petani yang baik dan akurat berbasis pengolahan citra.

Pengolahan citra digital (*digital image processing*) merupakan disiplin ilmu yang mempelajari tentang teknik-teknik mengolah citra (Sutoyo *et al.*, 2009). Pengolahan dan analisis citra melibatkan persepsi visual dan dalam prosesnya mempunyai ciri-ciri data masukan dan informasi keluaran berbentuk berkas citra digital (Daryanto, 2016). Pengolahan citra dapat memberikan informasi yang baik jika digabungkan dengan sistem pengambilan keputusan yang mampu memberikan akurasi yang tinggi (Kusumadewi, 2003). Teknologi pengolahan citra sudah banyak dikembangkan di dunia pertanian dan umumnya digunakan untuk mengukur, menguji, dan mengklasifikasikan suatu komoditas tertentu. Kemampuan pengolahan citra digital yang canggih memungkinkan proses identifikasi mutu komoditas pertanian menjadi lebih efektif dan efisien.

Penerapan pengolahan citra digital untuk penentuan mutu biji-bijian khususnya biji jagung sudah dilakukan oleh beberapa peneliti dengan tingkat keakurasian yang cukup baik. Pada penelitian yang dilakukan oleh Munarto *et al.* (2014) mengklasifikasikan mutu jagung manis berdasarkan fitur warna menggunakan *Fuzzy Logic* menghasilkan tingkat keakurasian sebesar 68%. Penelitian lain juga dilakukan oleh Bustomi dan Ahmad (2014) yang mengklasifikasikan mutu jagung berdasarkan distribusi intensitas RGB menggunakan Jaringan Syaraf Tiruan mampu menghasilkan keakurasian sebesar 73,75%. Adrizal *et al.* (2011) juga berhasil melakukan pendugaan mutu fisik biji jagung menggunakan Jaringan Syaraf Tiruan dengan ketepatan pendugaan rata-rata 77,50%.

Pada penelitian ini, identifikasi mutu jagung dilakukan dengan menggunakan algoritma *K-Nearest Neighbor* (K-NN) berdasarkan fitur warna HSV dan fitur tekstur GLCM. Penggunaan fitur warna HSV karena warna tersebut mirip dengan sistem penglihatan manusia, sedangkan fitur tekstur sesuai dengan pendugaan kadar air, karena tinggi rendahnya kadar air dapat mempengaruhi tekstur jagung. Penggunaan algoritma K-NN karena metode tersebut mampu mencapai hasil akurasi lebih tinggi (Gu *et al.*, 2009) serta lebih mudah dan lebih

handal untuk direpresentasikan (Arifin *et al.*, 2012) dibandingkan dengan algoritma klasifikasi lain seperti *Decision Tree* dan *Naive Bayessian*. Menurut Dzuida (2010), *K-Nearest Neighbor* (K-NN) merupakan algoritma sederhana yang termasuk dalam *classifier* kuat, namun membutuhkan nilai k dan penggunaan jarak yang tepat untuk menghasilkan akurasi yang tinggi. Selain itu, K-NN membutuhkan alokasi memori yang besar karena tidak membangun model klasifikasi dalam prosesnya.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka dapat dirumuskan masalah yaitu:

1. Bagaimana merancang sistem untuk mengidentifikasi mutu dan varietas jagung berdasarkan fitur warna dan tekstur berbasis pengolahan citra digital?
2. Bagaimana tingkat akurasi dalam pendugaan mutu jagung di tingkat petani menggunakan *K-Nearest Neighbor*?

1.3 Tujuan Penelitian

Dari rumusan masalah diatas, maka dapat ditentukan tujuan dari penelitian ini adalah:

1. Merancang sistem yang dapat digunakan untuk mengidentifikasi mutu dan varietas jagung berdasarkan fitur warna dan tekstur
2. Menentukan tingkat akurasi metode *K-Nearest Neighbor* dalam menduga mutu jagung di tingkat petani

1.4 Manfaat Penelitian

Manfaat dari penelitian ini yaitu mengembangkan teknologi pengolahan citra digital guna meningkatkan konsistensi serta mampu memberikan informasi akurat dalam mengidentifikasi mutu jagung di tingkat petani (produsen). Hasil dari penelitian ini diharapkan dapat memberikan manfaat dalam bidang pertanian dan perdagangan terutama bagi *supplier* jagung maupun pedagang yang membutuhkan alat bantu untuk identifikasi mutu jagung berdasarkan warna dan tekstur berbasis pengolahan citra digital, serta dapat dijadikan sebagai referensi dalam membuat mesin *grading* jagung secara otomatis.

BAB II TINJAUAN PUSTAKA

2.1 Jagung

Tanaman jagung (*Zea mays* L.) merupakan jenis tanaman biji-bijian dari keluarga rumput-rumputan (*Graminaceae*) yang populer di dunia. Jagung merupakan bahan baku utama pakan unggas (sekitar 50% dari ransum). Kandungan kimia jagung terdiri dari karbohidrat (61%), air (13,5%), protein kasar (10%), lemak (4%), gula (1,4%), pentosan (6%), serat kasar (2,3%), abu (1,4%), dan zat-zat lain (0,4%), (Rukmana, 1997). Pada jagung kuning (**Gambar 2.1**) mengandung *karotenoid* berkisar antara 6,4-11,3 $\mu\text{g/g}$, 22% diantaranya *beta-karoten* dan 51% *xantofil* (Koswara dalam Aini, 2013). Karakteristik kimia jagung tersebut menunjukkan bahwa jagung mempunyai nilai gizi yang cukup tinggi untuk dijadikan sebagai bahan pakan.



Gambar 2.1 Jagung kuning (DKPP, 2015)

Pemanfaatan jagung sebagai bahan pakan (biji maupun tongkolnya), diambil minyaknya (dari bulir), dibuat tepung (dari bulir) yang dikenal dengan tepung maizena, sebagai bahan baku industri (dari tepung bulir dan tepung tongkol) dan sumber energi alternatif (dari tongkol) (Respati *et al.*, 2013). Jagung sebagai pakan ternak dibagi menjadi dua kelompok yaitu untuk ruminansia dan bukan ruminansia. Umumnya ternak ruminansia memanfaatkan limbah jagung berupa jerami dan tanaman

jagung muda (umur 60 harian) sebagai hijauan. Jagung biji hampir seluruhnya dimanfaatkan untuk pakan ternak bukan ruminansia dan sedikit untuk pakan sapi perah. Salah satu kelebihan jagung untuk bahan pakan unggas terutama ayam petelur adalah kandungan *xantofil* yang berguna untuk menjadikan warna kuning telur lebih cerah. Bahan ini tidak dijumpai pada biji-bijian lain, dedak maupun ubi kayu (Tangendjaja *et al.*, 2005).

2.1.1 Jenis-jenis jagung

Berdasarkan bentuk, tekstur dan kandungan pati dalam biji (endosperma), jenis jagung dapat digolongkan menjadi tujuh tipe antara lain (Purwono dan Hartono, 2005):

- a. Jagung gigi kuda (*dent corn*), biji berbentuk gigi dan berlekuk. Lekukan terjadi karena pati keras terdapat di pinggir dan pati terdapat di pinggir dan pati lembek di puncak biji
- b. Jagung mutiara (*flint corn*), berbentuk bulat dan umumnya berwarna putih. Bagian luar biji keras dan licin karena terdiri dari pati keras
- c. Jagung manis (*sweet corn*), mengandung lebih banyak gula daripada pati sehingga bila kering bijinya keriput
- d. Jagung berondong (*pop corn*), biji sangat kecil dan termasuk dalam tipe jagung mutiara tetapi bagian bawah bijinya terdiri atas pati keras. Biji sangat kecil dan bila dipanaskan menjadi berondong (*popping*)
- e. Jagung tepung (*flour corn*), biji jagung terdiri dari pati yang sangat lunak
- f. Jagung polong (*pod corn*), biji dibungkus oleh kelobot, sementara seluruh tongkol juga terbungkus oleh kelobot seperti halnya jagung biasa
- g. Jagung ketan (*waxy corn*), memiliki kandungan amilopektin lebih besar dari amilosa dalam endospermanya yang menyebabkan rasa pulen pada jagung.

Secara umum terdapat dua jenis varietas jagung yang berkembang di tingkat petani yaitu varietas bersari bebas (VBB) atau komposit dan varietas hibrida. Varietas bersari bebas

termasuk juga didalamnya varietas tradisional atau varietas lokal yang bisa dipelihara petani. Varietas bersari bebas dihasilkan melalui rekombinasi sejumlah *fenotipe* terpilih yang relatif seragam yang mewakili porsi populasi yang diperbaiki kinerja genetiknya (Zubachtirodin dan Firdaus, 2012). Penggunaan varietas unggul hibrida mulai dikembangkan guna meningkatkan produksi tanaman jagung di Indonesia, contoh yang sering digunakan petani yaitu varietas hibrida Pertiwi 3 dan Pertiwi 6 yang merupakan produk perusahaan benih nasional, PT Agri Makmur Pertiwi. Keunggulan dari jagung hibrida Pertiwi 3 adalah memiliki ketahanan terhadap cekaman bulai, karat daun dan hewan serta memiliki rata-rata hasil 9,64 ton/ha dan memiliki potensi hasil yang tinggi yaitu 13,74 ton/ha pipilan kering (Kementerian Pertanian, 2014). Sebagai contoh, benih jagung varietas pertiwi 3 dan pertiwi 6 dalam kemasan ditunjukkan pada **Gambar 2.2(a)** dan **Gambar 2.2(b)**.



(a)



(b)

Gambar 2.2 (a) Varietas Pertiwi 3, (b) Varietas Pertiwi 6

2.1.2 Mutu jagung

Mutu jagung secara fisik ditentukan oleh warna, kenampakan dan tekstur sedangkan secara kimia dilakukan melalui serangkaian analisis seperti pengujian kadar air dan kadar aflatoksin. Penurunan mutu jagung yang sering terjadi antara lain memiliki kadar air tinggi, rusaknya butiran jagung, warna butir tidak seragam, adanya butir yang pecah serta kotoran lain sehingga berakibat pada rendahnya kualitas jagung

yang dihasilkan (BPTP, 2009). Standar mutu yang harus dipenuhi jagung sebagai bahan baku pakan sangat diperlukan untuk memberi jaminan bagi petani penghasil serta jaminan mutu pakan ternak yang menggunakannya. Jagung sebagai bahan baku pakan menurut SNI 4483-2013 digolongkan ke dalam dua tingkatan mutu yaitu mutu I dan mutu II (**Tabel 2.1**), sedang persepsi tingkat kerusakan pada biji jagung didefinisikan dalam kategori fisik biji jagung (**Tabel 2.2**).

Tabel 2.1 Standar mutu jagung berdasarkan SNI 4483-2013

No	Jenis uji	Satuan	Persyaratan	
			Mutu I	Mutu II
1	Kadar air (maks)	%(bb)	14,0	16,0
2	Kadar protein kasar (min)	%	8,0	7,0
3	Mikotoksin			
	a. Aflatoksin (maks)	µg/kg	100,0	150,0
	b. Okratoksin (maks)	µg/kg	20	-
4	Biji rusak (maks)	%	3,0	5,0
5	Biji berjamur (maks)	%	2,0	5,0
6	Biji pecah (maks)	%	2,0	4,0
7	Benda asing (maks)	%	2,0	4,0

Sumber : BSN, 2013

Tabel 2.2 Definisi fisik biji jagung menurut SNI 4483-2013

No	Fisik biji jagung	Definisi
1	Biji utuh	Biji jagung kering yang secara fisik keseluruhannya utuh tanpa adanya bercak, cacat ataupun jamur
2	Biji rusak	Biji jagung yang pecah yang mengalami kerusakan karena pengaruh mekanis, biologis, fisik dan enzimatik
3	Biji pecah	Biji jagung yang pecah selama proses pengolahan yang memiliki ukuran minimal 0,6 bagian jagung yang utuh
4	Biji berjamur	Biji jagung yang sudah terserang jamur yang warnanya sudah berubah dari warna aslinya
5	Benda asing	Semua benda selain jagung

Sumber : BSN, 2013

Adapun mutu jagung di tingkat petani dikategorikan berdasarkan PERMENDAGRI No.27/M-DAG/PER/5/2017 ditunjukkan pada **Tabel 2.3**. Mutu tersebut didasarkan pada kadar air dan digunakan sebagai acuan penetapan harga beli jagung di tingkat petani.

Tabel 2.3 Syarat mutu sebagai acuan harga pembelian jagung di tingkat petani

No	Kriteria	Harga (Rp)
1	Kadar air 15%, Aflatoksin 100 ppb, biji rusak, biji pecah 2%, biji berjamur 2%, benda asing 2%	3.150/kg
2	Kadar air 20%, Aflatoksin 100 ppb, biji rusak, biji pecah 2%, biji berjamur 2%, benda asing 2%	3.050/kg
3	Kadar air 25%, Aflatoksin 100 ppb, biji rusak, biji pecah 2%, biji berjamur 2%, benda asing 2%	2.850/kg
4	Kadar air 30%, Aflatoksin 100 ppb, biji rusak, biji pecah 2%, biji berjamur 2%, benda asing 2%	2.750/kg
5	Kadar air 35%, Aflatoksin 100 ppb, biji rusak, biji pecah 2%, biji berjamur 2%, benda asing 2%	2.500/kg


Sumber : Kementrian Perdagangan, 2017

2.2 Citra Digital

Citra merupakan fungsi intensitas dua dimensi $f(x,y)$, dimana x, y adalah koordinat spasial dan amplitudo f pada titik koordinat (x,y) merupakan tingkat kecerahan (tingkat keabuan) suatu citra pada suatu titik (Sulistyo, 2009). Apabila nilai x,y dan nilai amplitudo f secara keseluruhan berhingga (*finite*) dan bernilai diskrit maka dapat dikatakan bahwa citra tersebut adalah citra digital (Putra, 2010). Posisi koordinat citra digital ditunjukkan pada **Gambar 2.3**. koordinat ini dinyatakan dalam bilangan bulat positif yang dimulai dari 0 atau 1 tergantung pada sistem digital yang mempresentasikan informasi yang diwakili oleh titik tersebut (Sutoyo, 2009).

Pada umumnya, citra digital berbentuk empat persegi panjang dan dimensi ukurannya dinyatakan sebagai tinggi x lebar (atau lebar x panjang). Citra digital yang berukuran $N \times M$ dinyatakan dengan matriks yang berukuran N baris dan M kolom (Munir, 2004). Representasi f dalam sebuah matriks

dapat dilihat pada persamaan 2.1. Nilai pada suatu irisan dan kolom (pada posisi x,y) disebut dengan *picture element*, *image element*, *pels*, atau *pixels*, sehingga pada citra yang berukuran $N \times M$ mempunyai NM buah piksel (Putra, 2010).




Gambar 2.3 Koordinat citra digital (Putra, 2010)

$$f(x,y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{bmatrix} \dots (2.1)$$

2.2.1 Citra biner

Citra biner merupakan citra digital yang hanya memiliki dua kemungkinan nilai piksel yaitu hitam dan putih. Citra biner juga disebut sebagai citra B&W (*black and white*) atau citra monokrom karena hanya dibutuhkan 1 bit untuk mewakili setiap piksel (Putra, 2010). Citra biner hanya memiliki dua kemungkinan nilai pada setiap piksel-pikselnya yaitu 0 atau 1. Nilai 0 adalah *background points*, bukan merupakan bagian dari citra sesungguhnya. Nilai 1 merupakan *region points*, yaitu bagian dari citra sesungguhnya (bukan latar/*background*) (Crisnanto, 2011). **Gambar 2.4** merupakan contoh citra biner biji gandum.




Gambar 2.4 Citra Biner (Zhang *et.al.*, 2016)

Citra biner merupakan hasil transformasi dari citra asli menjadi citra B&W (*black and white*) yang digunakan untuk proses pengenalan dan segmentasi dengan tetap mempertahankan informasi seperti bentuk dan posisi dari citra aslinya (Kim, 2016). Citra biner telah melalui proses pemisahan piksel-piksel berdasarkan derajat keabuan yang dimiliki. Nilai setiap piksel dari citra biner direpresentasikan dalam satu bit (satu nilai *binary*). Citra biner banyak dimanfaatkan untuk keperluan *pattern recognition* seperti pengenalan angka, huruf maupun tanda tangan (Sunarya *et al.*, 2015).

2.2.2 Citra grayscale

Citra *grayscale* merupakan citra digital dimana nilai setiap piksel merupakan nilai tunggal. Nilai tersebut hanya menunjukkan informasi berupa intensitas tetapi tidak ada informasi mengenai warna/kromatik. Warna yang dimiliki citra *grayscale* berupa hitam sebagai intensitas terlemah, putih sebagai yang terkuat dan keabuan (Biswas *et al.*, 2011). Citra *grayscale* merupakan tingkatan warna keabuan. Warna abu-abu memiliki komponen warna *Red Green Blue* (RGB) dengan intensitas yang sama. Pada citra beraras keabuan hanya perlu menyatakan nilai intensitas untuk tiap piksel sebagai nilai tunggal sedangkan pada citra berwarna perlu tiga nilai intensitas untuk tiap pikselnya (Praharasty, 2008). Intensitas citra beraras keabuan disimpan sebagai integer 8 bit sehingga memberikan $2^8=256$ tingkat keabuan dari warna hitam sampai warna putih. Dengan menggunakan pola 8 bit tersebut, citra beraras keabuan membutuhkan ruang memori disk dan waktu pengolahan lebih

sedikit daripada citra berwarna (RGB) (Santi, 2011). Contoh Gambar citra *grayscale* biji gandum dapat dilihat pada **Gambar 2.5**.



Gambar 2.5 Citra *Grayscale* (Zhang *et.al.*, 2016)


2.2.3 Citra warna RGB (*Red, Green, Blue*)

Citra berwarna atau biasa disebut dengan citra RGB merupakan jenis citra yang menyajikan warna dalam bentuk komponen *Red* (merah), *Green* (hijau) dan *Blue* (biru). Setiap titik atau piksel pada citra warna memiliki nilai warna yang dinyatakan dalam nilai parameter R,G dan B (Wahyudi *et al.*, 2015). Setiap parameter warna menggunakan 8 bit yang nilainya berkisar antara 0 sampai dengan 255. Berdasarkan jangkauan nilai parameter R, G dan B pada citra warna, maka kemungkinan warna yang bisa disajikan mencapai 16.777.216 ($256 \times 256 \times 256$) warna (Sujito dan Mamud, 2016). Contoh Gambar citra warna biji gandum ditunjukkan pada **Gambar 2.6**.



Gambar 2.6 Citra warna (Kippes *et al.*, 2016)

Pada model RGB, tiga warna primer merah, hijau dan biru dapat diturunkan. Dalam spektrum cahaya, warna ketiganya digabungkan secara bersamaan menjadi satu warna, serta dapat dikombinasikan untuk menghasilkan spektrum warna baru (Wen dan Chun, 2004) seperti pada **Gambar 2.7**. Menurut Plataniotis dan Venetsanopoulos *dalam* Ibraheem *et al.* (2012), model warna RGB dikelompokkan menjadi dua tipe yaitu ruang warna RGB linier dan ruang warna RGB non-linier. Ruang warna RGB linier mencapai konsistensi warna menggunakan sistem manajemen warna. RGB linier tidak cocok untuk penggunaan analisis numerik dan jarang digunakan untuk representasi citra, biasanya digunakan untuk aplikasi grafis komputer. Pada ruang warna RGB non-linier, data citra masukan bernilai R'G'B yang direpresentasikan dalam kisaran 0 sampai 255.




Gambar 2.7 Model warna RGB (Ibraheem *et al.*, 2012)

2.2.4 Citra Warna HSV (*Hue, Saturation, Value*)

Selain warna RGB, warna citra juga dapat dimodelkan berdasarkan atribut warnanya. Model warna HSV dapat didefinisikan sebagai tampilan lain dari ruang warna RGB, sehingga dapat diartikan pula bahwa nilai HSV merupakan hasil transformasi dari RGB menggunakan metode geometrik (Deswal dan Neetu, 2014). HSV yang terdiri dari *Hue*, *Saturation* dan *Value* merepresentasikan warna sesuai dengan fitur penglihatan manusia. Model warna HSV mendefinisikan ruang warna menjadi tiga komponen diantaranya *Hue* yang memiliki *range* warna 0-360, *Saturation* merupakan tingkat

kemurnian warna yang memiliki *range* warna 0-100%, *Value* merupakan tingkat kecerahan warna memiliki *range* 0-100%. HSV merupakan bentuk geometris dari silinder (**Gambar 2.8**), dengan *Hue* sebagai dimensi sudut, mulai dari merah primer pada 0°, melewati hijau primer pada 120°, dan biru primer pada 240°, kemudian kembali ke warna merah pada 360° (Chitra dan Balakrishnan, 2012).



Gambar 2.8 Model warna HSV (Deswal dan Neetu, 2014)

Hue merupakan suatu ukuran panjang gelombang yang terdapat pada warna dominan yang diterima oleh penglihatan. *Saturation* menyatakan tingkat kemurnian warna cahaya, yaitu mengindikasikan seberapa banyak warna putih yang diberikan pada warna. *Saturation* mempresentasikan ukuran (kuantitas) dari keabuan pada *Hue* (Munarto *et al.*, 2014). *Hue* mengacu pada kisaran warna *Red*, *Green*, *Yellow* dan lainnya. Nilai saturasi mempengaruhi kemurnian warna yang dapat dibedakan mulai dari *gray* (bernilai 0) hingga *full saturated* atau disebut juga warna asli/murni (bernilai 1) (Semary *et al.*, 2013). *Value* dapat didefinisikan jumlah cahaya dalam warna yang mampu membedakan warna hitam hingga variasi-variasi warna baru berdasarkan nilai kecerahan dari suatu warna. Adapun konversi warna RGB menjadi HSV sebagai berikut (Kour, 2015):

$$V = \frac{1}{3} (R + G + B) \quad \dots\dots (2.2)$$

$$S = 1 - \frac{3}{R + G + B} [\min(R, G, B)] \text{ atau}$$

$$S = \frac{1 - \min(R, G, B)}{V} \quad \dots\dots(2.3)$$

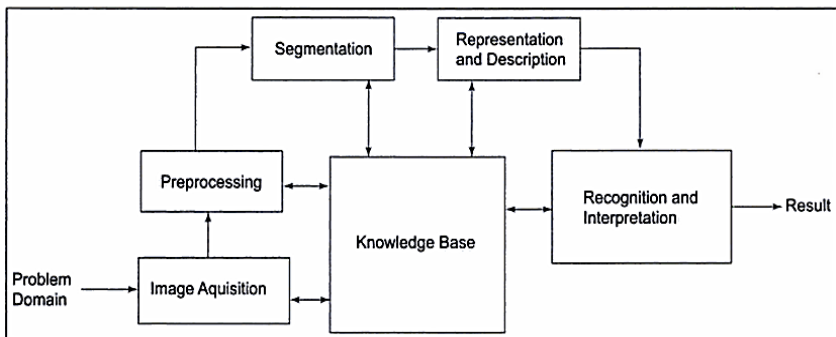
$$H = \theta \text{ jika } B \leq G \text{ atau } H = 360^\circ - \theta \text{ jika } B \geq G \quad \dots\dots(2.4)$$

Dimana :

$$\theta = \cos^{-1} \left\{ \frac{0,5 [((R - G) + (R - B))]}{\sqrt{(R - G)^2 + (R - B)(G - B)}} \right\} \quad \dots\dots(2.5)$$

2.3 Pengolahan Citra Digital

Pengolahan citra digital mengacu pada pemrosesan gambar dua dimensi menggunakan komputer. Dalam konteks yang lebih luas, pengolahan citra digital mengacu pada pemrosesan setiap data 2 dimensi (Putra, 2010). Pengolahan citra digital bertujuan untuk memperbaiki kualitas gambar (peningkatan kontras, translasi, skala, transformasi geometrik), melakukan proses penarikan informasi/ deskripsi objek atau pengenalan objek yang terkandung dalam citra, melakukan kompresi atau reduksi data untuk tujuan penyimpanan data, transmisi data, dan waktu proses data (Hermawati, 2013).



Gambar 2.9 Tahapan pengolahan citra digital (Annadurai dan Shanmugalakshmi, 2007)

Tahapan dalam pengolahan citra meliputi proses pembentukan citra (*image acquisition*), pengolahan citra tingkat awal (*image preprocessing*), segmentasi citra (*image*

segmentation), seleksi dan ekstraksi ciri (*feature extraction and selection*), serta pengenalan dan interpretasi (*recognition and interpretation*), (Annadurai dan Shanmugalakshmi, 2007). Tahapan pengolahan citra digital ditunjukkan pada **Gambar 2.9**. Penjelasan mengenai tahapan citra adalah sebagai berikut:

2.3.1 Akuisisi citra (*images acquisition*)

Akuisisi citra merupakan tahap awal untuk mendapatkan citra digital. Akuisisi citra bertujuan untuk menentukan data yang diperlukan dan memilih metode perekaman citra digital. Tahap ini dimulai dari objek yang akan diambil gambarnya, persiapan alat-alat, dan pada pencitraannya (Dey *et al.*, 2017). Dalam proses akuisisi, citra yang akan diolah dan ditransformasikan dalam suatu representasi numerik. Pada proses selanjutnya representasi numerik tersebut yang akan diolah secara digital oleh komputer (Fahmi, 2007).


2.3.2 Pengolahan citra tingkat awal (*image preprocessing*)

Pada pengolahan citra diperlukan proses *preprocessing* yang memiliki fungsi utama memperbaiki citra dengan meningkatkan kualitas citra melalui pengaturan kontras dan *brightness*, menghilangkan *noise*, restorasi citra, transformasi citra, dan menentukan bagian citra yang akan diobservasi (Klaus *et al.*, 2015). Proses *preprocessing* salah satunya dengan mengubah citra asli (warna/RGB) menjadi citra abu-abu (*grayscale*). Nilai intensitas untuk tiap piksel pada citra keabuan merupakan nilai tunggal dimana nilai intensitasnya berada pada interval 0-255, sedangkan pada citra berwarna perlu tiga nilai intensitas yang berada pada interval 0-255 untuk tiap pikselnya. Semakin mendekati nilai 255, maka derajat keabuan akan semakin terang. Pada dasarnya, proses ini dilakukan dengan meratakan nilai piksel dari 3 nilai RGB menjadi 1 nilai (Andono dan Pulung, 2015).

2.3.3 Segmentasi citra (*image segmentation*)

Segmentasi citra adalah proses pembagian suatu citra menjadi wilayah-wilayah yang homogen berdasarkan kriteria kemiripan tertentu antara tingkat keabuan suatu piksel dengan

tingkat keabuan piksel-piksel tetangganya. Segmentasi dideskripsikan sebagai proses analogi terhadap proses pemisahan latar depan dengan latar belakang (Sutoyo, 2009). Hasil dari segmentasi citra dinyatakan sebagai citra biner dengan tingkat keabuan yang berbeda-beda pada tiap wilayah yang berbeda. Segmentasi citra dapat dilakukan dengan menggunakan tiga teknik (ditunjukkan oleh **Gambar 2.10**) yaitu *thresholding*, *edge-based segmentation*, dan *region-based segmentation* (Zou dan Jiewen, 2015).



Gambar 2.10 Teknik segmentasi. a *Thresholding*. b *Edge-based segmentation*. c *Region based segmentation* (Zou dan Jiewen, 2015)

Thresholding merupakan segmentasi citra berbasis histogram dimana citra terbagi menjadi dua wilayah yaitu wilayah objek dan wilayah latar belakang. Wilayah objek di-set berwarna putih sedangkan sisanya di-set berwarna hitam (atau sebaliknya). Proses penentuan bagian objek dan latar belakang dapat dilakukan menggunakan *global thresholding* untuk mendapatkan nilai *threshold T* yang tepat. *Region segmentation* adalah segmentasi yang melakukan proses perhitungan karakteristik masing-masing daerah (*region*). Bagian citra yang memiliki karakteristik yang sama akan digabung dan dianggap satu bagian, sedangkan bagian yang memiliki karakteristik yang berbeda dilakukan pembagian dan perhitungan karakteristik kembali sampai seluruh bagian citra mempunyai karakteristik yang sama (Prasetyo, 2012). Segmentasi berdasarkan tepi (*Edge-based segmentation*) membagi suatu citra didasarkan pada diskontinuitas di antara sub-sub wilayah. Segmentasi ini didasarkan pada setiap *sub-region* dalam suatu citra yang cukup seragam, sehingga perbedaan di antara dua *sub-region*

dapat ditentukan pada dasar diskontinuitas itu sendiri (Synder, 2005).

2.3.4 Ekstraksi fitur (*feature extraction*)

Ekstraksi fitur adalah proses mengambil ciri-ciri yang terdapat pada objek di dalam citra untuk mengenali objek tersebut. Ekstraksi fitur merupakan langkah awal dalam melakukan klasifikasi dan interpretasi citra. Proses ini berkaitan dengan kuantisasi karakteristik citra ke dalam sekelompok nilai ciri yang sesuai (Ahmad, 2005). Ekstraksi fitur terbagi menjadi tiga macam yaitu ekstraksi fitur bentuk yang merupakan ekstraksi berdasarkan karakter konfigurasi permukaan yang diwakili oleh garis dan kontur, ekstraksi fitur tekstur merupakan ekstraksi yang didasarkan pada fitur tekstur serta ekstraksi fitur warna merupakan ekstraksi yang didasarkan pada fitur warna (Nahari, 2010).

2.3.5 Pengenalan dan interpretasi (*recognition and interpretation*)

Interpretasi citra adalah proses pengkajian citra melalui proses identifikasi dan penilaian mengenai objek yang tampak pada citra. Dengan kata lain, interpretasi citra merupakan suatu proses pengenalan objek yang berupa gambar (citra). Tahapan kegiatan yang diperlukan dalam pengenalan objek yang tergambar pada citra, yaitu 1) deteksi yaitu pengenalan objek yang mempunyai karakteristik tertentu oleh sensor, 2) identifikasi yaitu mencirikan objek dengan menggunakan data rujukan, 3) analisis yaitu mengumpulkan keterangan lebih lanjut secara terperinci (Somantri, 2009). Pengenalan objek merupakan bagian penting dalam interpretasi citra. Untuk itu, identitas dan jenis objek pada citra sangat diperlukan dalam analisis pemecahan masalah. Karakteristik objek pada citra dapat digunakan untuk mengenali objek yang dimaksud dengan unsur interpretasi (Lillesand *et al.*, 2004).

2.4 Analisis Tekstur

Tekstur merupakan karakteristik intrinsik dari suatu citra yang terkait dengan tingkat kekasaran (*roughness*), granularitas


(*granulation*), dan keteraturan (*regularity*) susunan struktural piksel. Aspek tekstural dari sebuah citra dapat dimanfaatkan sebagai dasar dari segmentasi, klasifikasi, maupun interpretasi citra (Karyanti, 2010). Tekstur merupakan salah satu ciri yang paling penting untuk analisis citra, dimana tekstur menyediakan informasi mengenai susunan struktur pada permukaan, perubahan intensitas, atau kecerahan warna (Siqueira *et al.*, 2013).

Tekstur dicirikan sebagai distribusi spasial dari derajat keabuan di dalam sekumpulan piksel-piksel suatu wilayah atau gambar. Suatu permukaan dikatakan memiliki informasi tekstur jika luasannya diperbesar tanpa mengubah skala, maka sifat-sifat permukaan hasil perluasan memiliki sifat kemiripan dengan permukaan asalnya (Dhian dan Kristian, 2016). Analisis tekstur bertujuan untuk mencari suatu deskripsi kuantitatif umum, efisien dan sederhana dari tekstur sehingga berbagai operasi matematis dapat digunakan untuk mengubah, membandingkan dan mentransformasikan tekstur (Rao dan Govardhan, 2012). Untuk mendapatkan nilai tekstur yaitu dengan melakukan ekstraksi fitur tekstur, salah satunya menggunakan metode *Gray Level Co-occurrence Matrix* (GLCM).

2.4.1 Gray Level Co-occurrence Matrix

Gray Level Co-occurrence Matrix (GLCM) merupakan matriks yang merepresentasikan hubungan ketetanggaan antar piksel dalam citra pada berbagai arah orientasi dan jarak spasial (Albregtsen, 2008). Suatu piksel yang bertetangga memiliki jarak d diantara keduanya dapat terletak di delapan arah yang berlainan (**Gambar 2.11**) (Ganis, 2011). Matriks kookurensi merupakan sebuah fungsi dua parameter yaitu jarak relatif yang diukur didalam jumlah piksel (d) dan orientasi relatifnya θ . Orientasi θ dikuantisasi ke dalam 4 arah yang mewakili horizontal, diagonal, vertikal dan anti-diagonal sebesar 0° , 45° , 90° , 135° (Aggrawal dan Kajnu, 2012). Matriks kookurensi berukuran $L \times L$, dimana L menyatakan banyaknya tingkat keabuan dengan elemen $P(x_1, x_2)$ yang merupakan distribusi probabilitas bersama (*joint probability distribution*) dari pasangan titik-titik dengan tingkat keabuan x_1 yang berlokasi

pada koordinat (j,k) dengan x_2 yang berlokasi pada koordinat (m,n). Koordinat pasangan titik-titik tersebut berjarak r dengan sudut θ (Putra, 2010):



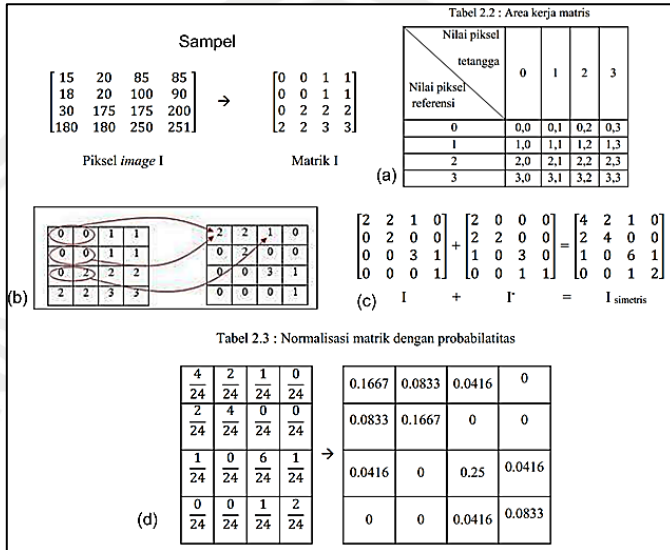
Gambar 2.11 Hubungan ketetangaan antar piksel sebagai fungsi orientasi dan jarak spasial (Ganis, 2011)

Tahapan dalam perhitungan GLCM meliputi a) membuat area kerja array GLCM ukuran $N \times N$ sesuai jumlah derajat keabuan, b) menghitung probabilitas kemunculan piksel dengan sudut θ dan jarak d, c) menghitung bentuk simetris dari array GLCM, d) normalisasi nilai dari langkah sebelumnya array GLCM dalam bentuk prosentase (Windana *et al.*, 2014). Contoh perhitungan GLCM *image grayscale* 4×4 dengan derajat keabuan antara 0 sampai 255 (**Gambar 2.12**). Matriks kookurensi akan dihitung dengan nilai $d=1$ dan $\theta=0^\circ$. Jumlah frekuensi munculnya pasangan (i,j) dihitung untuk keseluruhan matriks. Untuk mengubah rentang nilai intensitas piksel nilai *grayscale* 0 – 235 menjadi empat aras keabuan dengan nilai min 0 dan max 3 menggunakan rumus *min-max normalization* pada persamaan 2.6 (Purnamasari dan Sutojo, 2016).

$$I_N = (I - Min) \frac{newMax - newMin}{Max - Min} + newMin \quad \dots\dots (2.6)$$

Dimana :
I = nilai piksel

Max = nilai maksimal variabel /
Min = nilai minimum variabel /
newMax = nilai baru maksimal
newMin = nilai baru minimum



Gambar 2.12 Perhitungan GLCM (Windana *et al.*, 2014)

Tahapan setelah matriks kookurensi diperoleh, maka dapat dilanjutkan untuk menghitung fitur tekstur GLCM. Fitur GLCM terdiri atas perhitungan nilai *contrast*, *correlation*, *energy*, dan *homogeneity*. Formulasi matematika fitur GLCM dijelaskan pada persamaan berikut (Suresh, 2012):

a. *Contrast* : menunjukkan ukuran variasi intensitas keabuan suatu daerah citra.

$$Contrast = \sum_{i,j} |i - j|^2 p(i,j)^2 \quad \dots (2.7)$$

b. *Correlation* : menunjukkan ukuran ketergantungan linier derajat keabuan citra, sehingga dapat memberikan petunjuk adanya struktur linear dalam citra.

$$Correlation = \sum_{i,j} \frac{(i - \mu_i)(j - \mu_j)p(i,j)}{\sigma_i \sigma_j} \dots (2.8)$$

- c. *Energy* : menunjukkan ukuran konsentrasi pasangan dengan intensitas keabuan tertentu pada matriks. *Energy* disebut juga *Angular Second moment* (ASM) menunjukkan nilai yang tertinggi saat piksel-piksel gambar homogen.

$$Energy = \sum_{i,j} p(i,j)^2 \dots (2.9)$$

- d. *Homogeneity* : menunjukkan nilai distribusi antara elemen.

$$Homogeneity = \sum_{i,j} \frac{p(i,j)}{1 + |i - j|} \dots (2.10)$$


Dimana :

- i, j = baris ke- i , kolom ke- j
- $p(i, j)$ = piksel di lokasi baris ke- i kolom ke- j
- $\mu_i \mu_j$ = rata-rata dari $p(i, j)$
- $\sigma_i \sigma_j$ = standar deviasi $p(i, j)$

2.5 Algoritma *K-Nearest Neighbor*

Algoritma *K-Nearest Neighbor* (K-NN) merupakan algoritma yang melakukan klasifikasi berdasarkan kedekatan lokasi (jarak) suatu data dengan data yang lain (Tan *et al.*, 2006). K-NN termasuk algoritma *supervised learning* yang bertujuan untuk menemukan pola baru dalam data dengan menghubungkan pola data yang sudah ada dengan data yang baru (Wu dan Vipin, 2009). Algoritma K-NN mengklasifikasikan objek baru berdasarkan atribut dan data *training*, dimana proses pengklasifikasian data uji didasarkan pada mayoritas dari kategori algoritma K-NN (Han *et al.*, 2011). K-NN termasuk dalam kategori algoritma *lazy learner* yang hanya sedikit melakukan pelatihan, hanya menyimpan sebagian atau seluruh data latih, kemudian menggunakannya dalam proses prediksi (Maillo *et al.*, 2017).

Metode K-NN melakukan klasifikasi suatu data dengan mengidentifikasi sejumlah k tetangga terdekat data latih, kemudian melakukan prediksi terhadap data uji dengan mengambil kelas terbanyak dalam menentukan jenis kelas dari data tersebut (Zhang *et al.*, 2016), dimana k merupakan angka bernilai positif (Bora *et al.*, 2015). Setiap data merepresentasikan sebuah titik dalam kelas. Data latih disimpan dalam kelas yang telah ditentukan. Ketika diberikan data yang tidak diketahui kelasnya, K-NN akan mencari pola sebanyak k data latih yang dekat dengan data yang belum memiliki kelas. Sehingga kinerjanya sangat tergantung pada metrik jarak yang digunakan untuk mengidentifikasi tetangga terdekat (Weinberger *et al.*, 2006). Visualisasi proses klasifikasi K-NN ditunjukkan pada **Gambar 2.13**.



Gambar 2.13 Klasifikasi K-NN. Label titik *query* tergantung pada nilai k (1,5 atau 10). Titik *query* dapat dikategorikan label persegi (a), *diamond* (b) dan segitiga (c) (Kim, 2012)

2.5.1 Tahapan Klasifikasi K-NN

Pada algoritma K-NN, data berdimensi q , jarak dari data tersebut ke data yang lain dapat dihitung. Nilai jarak inilah yang digunakan sebagai nilai kedekatan/kemiripan antara data uji dengan data latih. Jarak minimum antara data uji dan data latih dihitung untuk menentukan kategori K-NN (Mansor, 2013). Metode K-NN menggunakan jarak *Euclidean* atau metode pembelajaran metrik lainnya untuk mengukur perbedaan atau kemiripan antara data latih dan data uji. Semakin besar nilai

Euclidean distance, akan semakin jauh tingkat kemiripan antara data uji dan data latihnya. Sebaliknya jika nilai *Euclidean distance* semakin kecil, maka akan semakin dekat tingkat kemiripan antara data uji dan data latihnya (Luhulima *et al.*, 2015). Adapun tahapan klasifikasi K-NN adalah sebagai berikut (Liantoni, 2015):

- a. Menentukan parameter nilai k (jumlah tetangga terdekat)
- b. Menghitung jarak data uji ke data latih
- c. Mengurutkan data berdasarkan data dengan jarak terkecil
- d. Menentukan kelompok data uji berdasarkan label mayoritas pada nilai k

2.5.2 Metode perhitungan jarak

Metode perhitungan jarak (kesamaan atau kemiripan citra) merupakan aspek penting dalam pengembangan metode klasifikasi maupun regresi. Sebelum dilakukan klasifikasi data atau objek untuk dideteksi, terlebih dahulu ditentukan ukuran jarak kedekatan antar elemen data (Nugraheny, 2015). Metode perhitungan jarak yang sering digunakan antara lain berdasarkan jarak *Euclidean* dan *Cityblock (Manhattan)*. *Euclidean* sering digunakan karena penghitungan jarak dalam *distance space* ini merupakan jarak terpendek yang bisa didapatkan antara dua titik yang diperhitungkan, sedangkan *Cityblock* sering digunakan karena kemampuannya dalam mendeteksi keadaan khusus seperti keberadaan *outlier* dengan lebih baik (Prasetyo, 2012). Berikut rumus perhitungan jarak *Euclidean* dan *Cityblock*:

a. *Euclidean distance*

Metode *Euclidean* membandingkan jarak minimum data uji dengan data latih. Jarak *Euclidean* dari dua vektor x dan y dihitung dengan persamaan 2.11 (Wurdianarto *et al.*, 2014). Fungsi $d(x,y)$ adalah jarak antara dua data, n adalah jumlah parameter penduga. Jarak *Euclidean* yang semakin kecil menunjukkan kesamaan yang lebih tinggi. Jarak 0 berarti bahwa data sama (Trstenjak *et al.*, 2014).

$$d(x, y) = \sqrt{\sum_{k=1}^n (x_i - y_i)^2} \quad \dots (2.11)$$

Dimana :

d_{xy} = tingkat perbedaan (*dissimilarity degree*)

n = jumlah *vector*

x_i = vektor citra *input*

y_i = vektor citra *pembanding (output)*

b. *Cityblock distance*

Cityblock distance atau disebut juga jarak *Manhattan* merupakan salah satu pengukuran yang paling banyak digunakan meliputi penggantian perbedaan kuadrat dengan menjumlahkan perbedaan *absolute* dari variabel. Prosedur ini disebut blok *absolute* atau lebih dikenal dengan *Cityblock distance* (ditunjukkan pada persamaan 2.3) (Nugraheny, 2015). *Manhattan distance* mengukur berdasarkan penjumlahan jarak selisih tiap atribut yang dimiliki oleh obyek, sehingga pengukuran jarak menggunakan metode *Manhattan distance* dapat mencerminkan jarak sebenarnya antar suatu obyek (Sinwar dan Rahul, 2014).

$$d(x, y) = L_p = i(x, y) = \sum_i^n \|x_i - y_i\| \quad \dots (2.11)$$

2.6 Penelitian Terdahulu

Saeed *et. al* (2014) dengan judul penelitian "*Identification of Canola Seeds using Nearest Neighbor and K-Nearest Neighbor Algorithms*" merancang sistem identifikasi untuk mengetahui perbedaan varietas biji canola dengan menggunakan analisis fitur *RST-invariant*, histogram dan tekstur. Varietas biji calona diklasifikasikan ke dalam varietas I (*Gobhi Sarson*), varietas II (*Barassica comp*), varietas III (*Sathri*) dan varietas IV (*Rocket Herbof*). Algoritma yang digunakan untuk identifikasi varietas biji canola yaitu menggunakan metode *Nearest Neighbor* dan *K-Nearest Neighbor*. Pada K-NN, nilai k yang digunakan adalah 2 dan 3 dengan jarak *Euclidean* dan *Cityblock*. Total citra yang

digunakan sejumlah 40 citra (masing-masing varietas diambil sebanyak 10 citra). Berdasarkan simulasi secara keseluruhan, sistem dapat mengklasifikasikan varietas biji canola dengan hasil akurasi tertinggi diperoleh menggunakan metode K-NN pada saat $k=3$ menggunakan *Cityblock distance* yaitu sebesar 90,00%.

Gamit *et. al* (2015) dalam penelitiannya yang berjudul “*Flower Grain Image Classification Using Supervised Classification Algorithm*” melakukan identifikasi biji bunga matahari menggunakan fitur warna dan tekstur. Terdapat 7 jenis bunga matahari yang digunakan yaitu *Ranunculaceae*, *Solanaceae*, *Liliaceae*, *Compositae*, *Malvaceae*, *Rosaceae*, *Pinaceae*. Ekstraksi fitur warna yang digunakan yaitu warna HSV dan tekstur GLCM (*Gray Level Co-occurrence Matrix*) dengan metode ANN *Backpropagation*. Dataset citra yang digunakan sebanyak 122 citra, 77 citra sebagai data latih dan 35 data sebagai data uji. Hasil penelitian menunjukkan akurasi tertinggi sebesar 77,14% dengan mengkombinasikan fitur warna HSV dan tekstur GLCM.

Prahuyada dan Agus (2017) dengan judul penelitiannya “Metode Klasifikasi Mutu Jambu Biji Menggunakan K-NN Berdasarkan Fitur Warna dan Tekstur” membangun sistem pengklasifikasian mutu jambu biji menggunakan fitur warna, luas area cacat dan tekstur sebagai parameter. Penelitian dilakukan menggunakan fitur warna RGB, luas cacat dan tekstur GLCM menggunakan metode *K-Nearest Neighbor*, dengan variasi nilai k yang diuji yaitu 1,3,5,7,9 dan jarak yang digunakan *Euclidean*. Total citra yang diambil sebanyak 160 data dengan rasio pengujian 90%:10% (menggunakan metode *10-fold cross validation*). Hasil penelitian dengan menunjukkan akurasi tertinggi saat nilai $k = 3$ sebesar 91,25%.

BAB III METODE PENELITIAN

3.1. Tempat dan Waktu Pelaksanaan

Penelitian dilaksanakan di Laboratorium Teknik Pengolahan Pangan dan Hasil Pertanian, Jurusan Keteknikan Pertanian, sedang pengolahan data di Laboratorium Komputasi dan Analisis Sistem, Jurusan Teknologi Industri Pertanian, Fakultas Teknologi Pertanian, Universitas Brawijaya Malang. Penelitian dilakukan mulai bulan Agustus 2017 sampai Januari 2018.

3.2. Alat dan Bahan

Bahan penelitian ini adalah jagung pipilan yang diperoleh dari petani jagung di kabupaten Tuban, Jawa Timur. Jagung pipilan yang digunakan yaitu varietas Pertiwi 3 dan Pertiwi 6 masing-masing terdiri dari pipilan basah, setengah kering dan kering. Selain jagung pipilan utuh, juga digunakan jagung pipilan dengan biji pecah, biji rusak dan biji berjamur. Peralatan yang digunakan ialah perangkat pengambilan citra meliputi perangkat keras dan perangkat lunak. Perangkat keras terdiri dari kotak pengambilan citra, lampu, laptop, *handphone* dan kabel USB. Perangkat lunak pengolahan citra menggunakan pemrograman Matlab R2012a.

3.3. Batasan Masalah

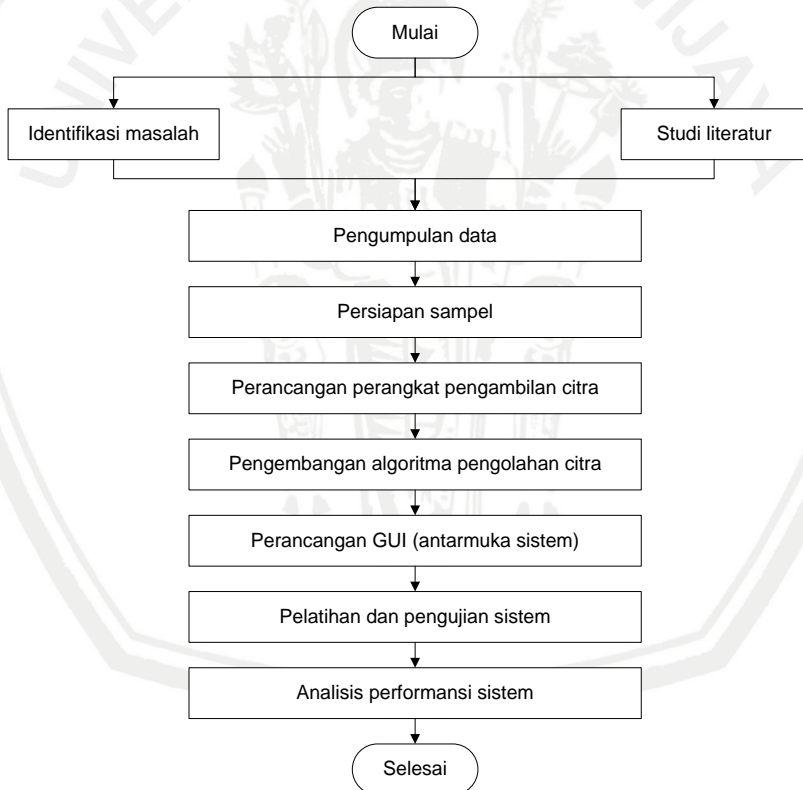
Penentuan batasan masalah dilakukan untuk membatasi ruang lingkup agar permasalahan tidak melebar, lebih terfokus pada tujuan yang ingin dicapai. Batasan masalah penelitian ini sebagai berikut:

- a. Jagung yang digunakan adalah jagung varietas Pertiwi 3 dan Pertiwi 6
- b. Mutu yang diukur berdasarkan kategori penentuan harga jagung di tingkat petani (kadar air sebagai acuan)
- c. Ukuran piksel dan resolusi yang digunakan pada masing-masing citra jagung sama (300x300 piksel)

- d. Citra yang diproses berdasarkan fitur warna dan tekstur, dimana mode warna citra yang digunakan pada ekstraksi ciri adalah warna *Hue*, *Saturation*, *Value* dan *Grayscale*.

3.4. Pelaksanaan Penelitian

Penelitian dilakukan melalui beberapa tahapan penelitian yang terdiri dari survei pendahuluan dan studi literatur, pengumpulan data, perancangan perangkat pengambilan citra, pengembangan algoritma pengolahan citra, persiapan sampel, perancangan GUI, pelatihan dan pengujian sistem serta perhitungan akurasi sistem identifikasi mutu jagung. Tahapan penelitian secara ringkas dapat dilihat pada **Gambar 3.1**.



Gambar 3.1 Tahapan penelitian

3.4.1 Identifikasi masalah

Identifikasi masalah merupakan tahap awal pada proses penelitian untuk menentukan objek penelitian yang diteliti. Proses identifikasi masalah dilakukan berdasarkan pada rumusan masalah yang didasari latar belakang masalah. Identifikasi masalah juga dilakukan melalui survei lapang yang bertujuan untuk mengetahui kondisi objek yang dijadikan sampel penelitian.

3.4.2 Studi literatur

Studi literatur bertujuan untuk mencari, mengumpulkan dan memahami baik dari jurnal-jurnal penelitian terdahulu, *textbook*, internet dan sumber lainnya yang mendukung pemecahan masalah dalam penelitian ini. Studi literatur digunakan sebagai referensi untuk mengetahui secara teoritis metode apa saja yang dapat digunakan dalam menyelesaikan masalah. Teori-teori yang digunakan diantaranya berkaitan dengan jagung, pengolahan citra digital dan metode klasifikasi *K-Nearest Neighbor* (K-NN).

3.4.3 Pengumpulan data

Pengumpulan data bertujuan untuk mendapatkan data yang diperlukan untuk membangun sistem identifikasi mutu jagung berbasis pengolahan citra digital. Data yang dibutuhkan dalam penelitian ini terdiri dari dua jenis data, yaitu data primer dan data sekunder. Data primer adalah data yang diperoleh secara langsung dari obyek yang diteliti untuk dianalisis lebih lanjut. Data sekunder adalah data pengamatan secara tidak langsung dan bersumber dari dokumen. Data sekunder dapat berupa jurnal dan buku literatur yang relevan dengan penelitian.

3.4.4 Persiapan sampel

Tahap awal sebelum pengambilan citra jagung, terlebih dahulu dilakukan pemutuan terhadap biji jagung yang digunakan sebagai sampel. Sistem identifikasi mutu jagung didasarkan standar Peraturan Menteri Perdagangan RI No.27/M-DAG/PER/5/2017 mengenai penetapan harga jagung di tingkat

petani dengan kadar air sebagai acuannya. Sampel yang digunakan pada penelitian yaitu jagung pipilan varietas Pertiwi 3 dan Pertiwi 6. Terdapat 10 kelas kategori yang diharapkan dari proses klasifikasi mutu jagung sebagai berikut:

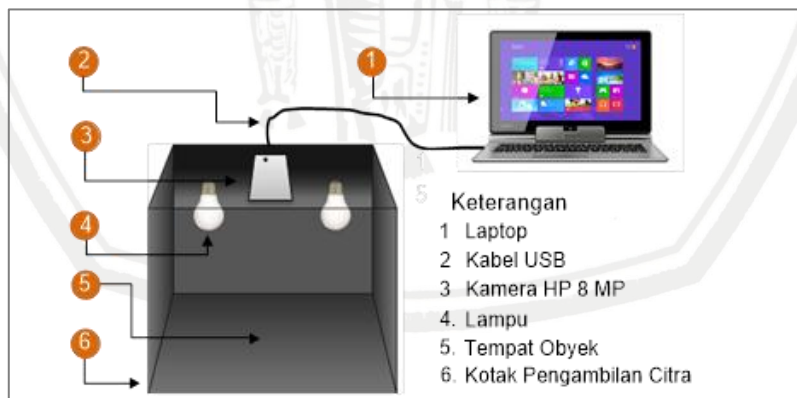
- 1) Kategori 1, Varietas Pertiwi 3 memiliki kriteria kadar air maksimal 15% dengan konsekuensi harga beli jagung Rp. 3.150,-/kg
- 2) Kategori 2, Varietas Pertiwi 3 memiliki kriteria kadar air maksimal 20% dengan konsekuensi harga beli jagung Rp. 3.050,-/kg
- 3) Kategori 3, Varietas Pertiwi 3 memiliki kriteria kadar air maksimal 25% dengan konsekuensi harga beli jagung Rp. 2.850,-/kg
- 4) Kategori 4, Varietas Pertiwi 3 memiliki kriteria kadar air maksimal 30% dengan konsekuensi harga beli jagung Rp. 2.750,-/kg
- 5) Kategori 5, Varietas Pertiwi 3 memiliki kriteria kadar air maksimal 35% dengan konsekuensi harga beli jagung Rp. 2.500,-/kg
- 6) Kategori 6, Varietas Pertiwi 6 memiliki kriteria kadar air maksimal 15% dengan konsekuensi harga beli jagung Rp. 3.150,-/kg
- 7) Kategori 7, Varietas Pertiwi 6 memiliki kriteria kadar air maksimal 20% dengan konsekuensi harga beli jagung Rp. 3.050,-/kg
- 8) Kategori 8, Varietas Pertiwi 6 memiliki kriteria kadar air maksimal 25% dengan konsekuensi harga beli jagung Rp. 2.850,-/kg
- 9) Kategori 9, Varietas Pertiwi 6 memiliki kriteria kadar air maksimal 30% dengan konsekuensi harga beli jagung Rp. 2.750,-/kg
- 10) Kategori 10, Varietas Pertiwi 6 memiliki kriteria kadar air maksimal 35% dengan konsekuensi harga beli jagung Rp. 2.500,-/kg

Prosedur *sample preparation* jagung yaitu menyiapkan jagung pipilan basah, setengah kering dan kering tiap varietas. Selanjutnya sampel dibawa ke laboratorium pengujian untuk analisis kadar air menggunakan *moisture tester*. Sampel diukur

hingga didapatkan kelompok sampel dengan variasi kadar air 11% sampai 35% (tiap kelas kategori terdiri dari 5 variasi kadar air). Setiap kelompok sampel terdiri dari biji utuh dan maksimal 2% masing-masing biji pecah, biji rusak serta biji berjamur yang ditimbang sebanyak ± 20 gram menggunakan timbangan digital dengan ketelitian 0,01 gram. Selanjutnya dilakukan pengambilan citra tiap kelompok sampel sebanyak 10 kali dengan mengacak posisi butir, sehingga menghasilkan citra yang berbeda. Apabila terdapat 10 kelas kategori, maka keseluruhan data citra jagung yang diperoleh adalah 5 variasi kadar air \times 10 kelas kategori \times 10 kali pengambilan citra = 500 data citra.

3.4.5 Perancangan perangkat pengambilan citra

Sistem identifikasi mutu jagung terdiri dari perangkat keras (*hardware*) dan perangkat lunak (*software*). Perangkat keras digunakan untuk memudahkan proses pembacaan citra sedangkan perangkat lunak digunakan untuk mengidentifikasi citra jagung. Perangkat keras yang digunakan antara lain laptop, *handphone*, kabel USB, kotak pengambilan citra dan lampu, sedangkan perangkat lunak pengolahan citra menggunakan pemrograman Matlab R2012a. **Gambar 3.2** menunjukkan gambaran umum perangkat pengambilan citra.



Gambar 3.2 Perangkat pengambilan citra

1. Laptop

Laptop digunakan untuk membangun sistem identifikasi mutu jagung. Laptop berfungsi sebagai *user interface* untuk proses pengolahan citra jagung dan menampilkan output hasil identifikasi mutu.

2. Kabel USB

Kabel USB digunakan untuk menghubungkan *handphone* dengan komputer untuk memindahkan (*transfer*) data dari *handphone* ke komputer.

3. Kamera *Handphone*

Kamera yang digunakan untuk melakukan pengambilan citra jagung adalah kamera *handphone* LG K8 dengan resolusi kamera 8 MP. Kamera *handphone* berfungsi sebagai input dari sistem pengambilan citra jagung.

4. Kotak Pengambilan Citra

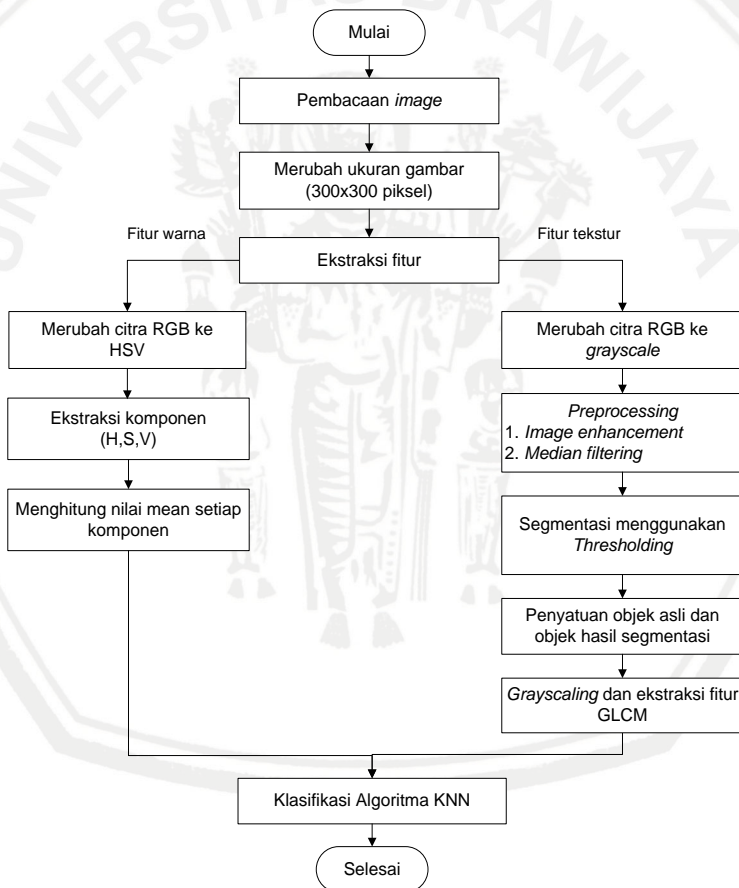
Kotak pengambilan citra digunakan sebagai tempat obyek yang akan di-*capture* dan diolah citranya. Ukuran kotak pengambilan citra yaitu 30cm x 30cm x 30cm. Pemilihan warna latar mempengaruhi kualitas citra yang diperoleh. Warna latar yang dipilih adalah warna biru tua karena warna tersebut kontras dengan warna biji jagung. Pada perangkat pengambilan citra, jarak kamera dengan obyek ditentukan sesuai jenis kamera dan kondisi saat kamera fokus dan tidak kabur. Selain itu, jarak pengambilan citra mempertimbangkan luas obyek yang diambil. Jarak yang digunakan dalam penelitian ini ± 12 cm.

5. Lampu

Lampu berfungsi sebagai sumber pencahayaan pada jagung yang diambil citranya menggunakan kamera *handphone*. Lampu yang digunakan dalam sistem identifikasi mutu jagung ini adalah lampu LED 5 watt sebanyak 2 buah yang diletakkan di atas kedua sisi obyek. Pemilihan lampu LED 5 watt ini berdasarkan penelitian yang sudah dilakukan oleh Dinar *et al.* (2012) menggunakan lampu LED 5 watt untuk akuisisi citra biji pala. Penentuan jarak antara lampu dengan obyek ditentukan pada saat kondisi penerang lampu bekerja lebih baik dan gambar yang diambil terlihat bagus.

3.4.6 Pengembangan algoritma pengolahan citra

Perangkat lunak yang digunakan dalam mengolah dan mengklasifikasikan citra jagung adalah Matlab R2012a. Terdapat beberapa proses yang harus dilakukan untuk membangun algoritma, dimulai dari proses pembacaan *image*, melakukan *resize* citra menjadi 300x300 piksel, ekstraksi fitur warna dan tekstur kemudian dilakukan proses klasifikasi menggunakan K-NN *classifiers*. Tahapan dalam pengembangan algoritma pengolahan citra ditunjukkan pada **Gambar 3.3**.



Gambar 3.3 Tahapan pengembangan algoritma pengolahan citra

1. Pembacaan *image*

Pembacaan *image* dilakukan agar dapat memproses suatu citra. Beberapa jenis file gambar yang dapat dibaca oleh Matlab antara lain JPEG, GIF, TIF, BMP. Pada penelitian ini, *image* yang diproses memiliki format JPEG. Matlab memiliki fungsi untuk melakukan pembacaan *image* standar yaitu *Imread('filename')*; Hasil pembacaan *imread('filename')*; bisa berupa matriks dua dimensi jika gambar yang dibaca adalah gambar *grayscale* dan matriks tiga dimensi jika berupa gambar tiga dimensi.

2. *Preprocessing*

Tahap *preprocessing* dilakukan untuk menghilangkan *noise* citra dan untuk meningkatkan kualitas citra. *Preprocessing* yang dilakukan yaitu *image enhancement* dan *median filtering*. *Preprocessing* penelitian ini hanya diperlukan sebelum ekstraksi fitur tekstur, sedangkan untuk ekstraksi fitur warna langsung diubah ke *channel* HSV.

3. Segmentasi

Tahap segmentasi mengklasifikasikan citra menjadi beberapa daerah atau *region* yang memiliki karakteristik yang sama. Tahap ini merupakan lanjutan dari tahap *preprocessing* sebelum dilakukan ekstraksi fitur tekstur. Metode segmentasi yang digunakan pada penelitian ini yaitu *thresholding*. *Thresholding* memisahkan antara objek dengan *background* berdasar perbedaan tingkat kecerahannya. Hasil dari proses *thresholding* berupa citra biner dengan nilai intensitas piksel sebesar 0 (*background*) atau 1 (objek). Hasil segmentasi kemudian disatukan kembali dengan objek asli sehingga menghasilkan citra warna tanpa *background*. Selanjutnya citra tersebut diubah menjadi *grayscale* untuk diperoleh nilai fitur teksturnya.

4. Ekstraksi fitur

Ekstraksi fitur dilakukan untuk mendapatkan nilai-nilai fitur unik yang mewakili karakteristik objek. Pada penelitian ini, ekstraksi ciri dilakukan menggunakan ekstraksi fitur warna dan fitur tekstur. Pada ekstraksi fitur warna menggunakan komponen HSV (dipilih karena mirip dengan sistem penglihatan manusia). Fitur warna didapatkan dengan menghitung nilai *mean* dari setiap komponen HSV,


sedang ekstraksi fitur tekstur (dipilih karena sesuai dengan pendugaan kadar air yang dapat mempengaruhi tekstur jagung) dilakukan menggunakan *Gray Level Co-occurrence Matrix* (GLCM). Fitur GLCM yang digunakan antara lain *contrast*, *correlation*, *energy*, dan *homogeneity*. Perhitungan fitur GLCM ditunjukkan pada persamaan 2.7, 2.8, 2.9, serta 2.10. Hasil fitur warna dan tekstur yang diperoleh selanjutnya digunakan sebagai parameter dalam proses klasifikasi.

5. Klasifikasi menggunakan K-NN

Pada penelitian ini, klasifikasi menggunakan metode *K-Nearest Neighbor* (K-NN). Metode K-NN dilakukan dengan membandingkan data uji dan data latih. Algoritma K-NN melakukan klasifikasi berdasarkan kedekatan jarak antara data uji dan data latih. Adapun tahapan klasifikasi sistem menggunakan K-NN sebagai berikut:

a. Menentukan nilai k

Pada proses ini, *user* memilih nilai k, yaitu jumlah tetangga terdekat. K-NN akan mencari pola sebanyak k data latih yang dekat dengan data uji yang belum diketahui kelasnya. Nilai k yang digunakan penelitian ini adalah 1,3,5,7, dan 9. Penggunaan nilai k ganjil menurut Prahudaya dan Agus (2017) bertujuan untuk menghindari kesamaan kedekatan pada dua titik yang berbeda kelas. Konsep sederhana K-NN ditunjukkan **Gambar 3.14**, dimana jumlah tetangga terdekat (*Nearest Neighbour/NN*) dimuat dalam rentang nilai k yang telah ditentukan.



Gambar 3. 4 K-NN dengan nilai k tetangga, (a) 1-NN, (b) 3-NN, (c) 5-NN, (d) 7-NN (Tobias dan Anastasia, 2016)

b. Perhitungan jarak

Tahap selanjutnya yaitu menghitung jarak vektor data uji dengan data latih. Nilai jarak inilah yang digunakan sebagai nilai kedekatan/kemiripan antara data uji dengan data latih. Jarak minimum antara data uji dan data latih dihitung untuk menentukan kategori K-NN. Perhitungan jarak menggunakan metode *Euclidean* dan *Cityblock*. Jarak *Euclidean* dan jarak *Cityblock* dihitung menggunakan persamaan 2.11 dan 2.12.

c. Pengurutan kemiripan vektor

Hasil perhitungan jarak menggunakan *Euclidean* dan *Cityblock* diurutkan berdasarkan nilai terkecil. Semakin kecil nilai jarak, maka data uji semakin mirip dengan data latih. Sebaliknya, semakin besar nilai jarak yang dihasilkan, maka semakin berbeda dengan data latih. Pengurutan nilai jarak dilakukan dengan mengkategorikan sejumlah k-data yang memiliki jarak terdekat sesuai dengan jumlah tetangga (nilai k) yang ditentukan terlebih dahulu.

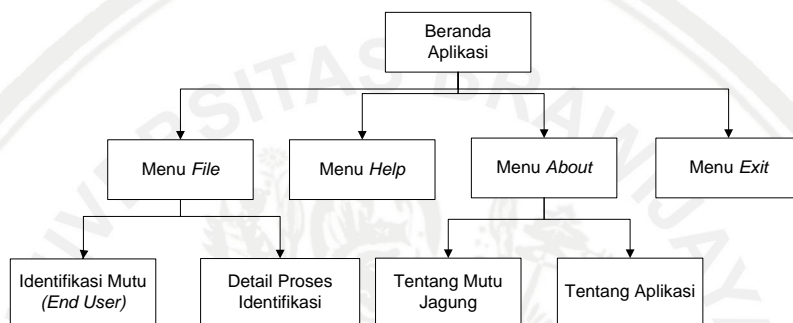
d. Mencari label mayoritas

Tahap terakhir dalam proses klasifikasi menggunakan K-NN yaitu mencari label mayoritas berdasarkan nilai k yang telah dipilih untuk menentukan hasil klasifikasi dengan melihat jumlah kelas terbanyak yang diperoleh diantara k data latih yang terdekat. Kelas data uji ditentukan berdasarkan label mayoritas diantara k tetangga terdekat yang terpilih.

3.4.7 Perancangan GUI (antarmuka sistem)

Perancangan GUI aplikasi dibuat untuk mempermudah penggunaan program identifikasi mutu jagung. Dalam pembuatan sebuah sistem atau aplikasi, antarmuka (*interface*) merupakan bagian penting sebagai interaksi antara *user* dan aplikasi yang akan dibangun. Sebelum membangun antarmuka yang nyata, diperlukan perancangan agar menghasilkan antarmuka yang sesuai dengan keinginan dan kebutuhan sistem itu sendiri. Struktur antarmuka sistem terdiri dari menu *file*,

menu *help*, menu *about* dan menu *exit*. Menu *file* berisi program utama yaitu identifikasi mutu jagung untuk *end user* dan detail proses identifikasi, menu *help* berisi petunjuk penggunaan aplikasi, menu *about* menjelaskan informasi tentang mutu jagung dan tentang aplikasi, serta menu *exit* untuk keluar dari aplikasi. Adapun struktur dari antarmuka sistem identifikasi mutu jagung ditunjukkan pada **Gambar 3.5**.



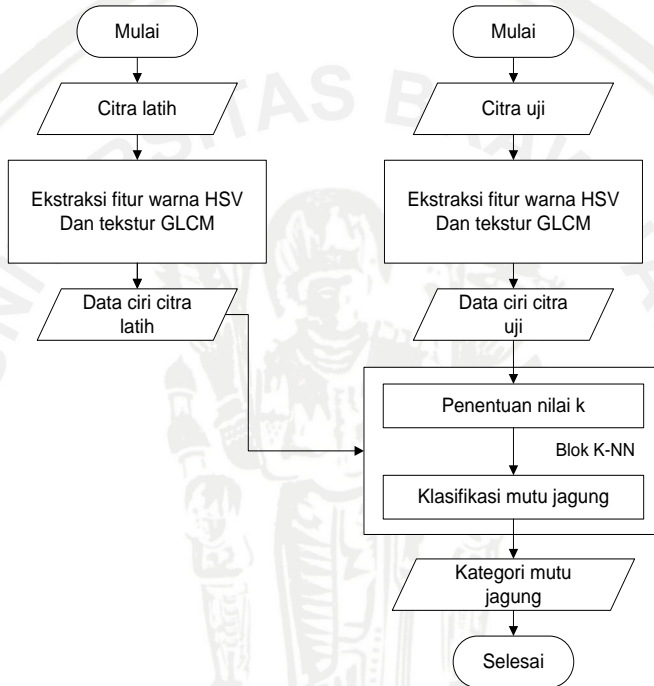
Gambar 3.5 Struktur antarmuka sistem

3.4.8 Pelatihan dan pengujian sistem

Tahap pelatihan perangkat lunak bertujuan untuk memberi pembelajaran terhadap sistem mengenai mutu jagung. Analisis sistem ditunjukkan pada **Gambar 3.6**. Pada tahap pengujian sistem dilakukan evaluasi terhadap berbagai kriteria yang berkaitan dengan sistem dan data yang digunakan seperti ketepatan dan konsistensi pada hasil yang diperoleh.

Tahap pengujian sistem bertujuan untuk mengetahui tingkat keberhasilan dan kemampuan sistem dalam mengklasifikasikan mutu jagung. Input sistem terdiri dari 7 parameter yakni 3 fitur warna H,S,V dan 4 fitur tekstur GLCM yaitu *Contrast*, *Correlation*, *Energy* dan *Homogeneity*. Data uji yang digunakan berbeda dengan data latih. Dalam pengujian sistem, rasio perbandingan data latih dan data uji yang digunakan adalah 70:30 dalam satuan persen (%). Dari total 500 data citra jagung yang diambil, sebanyak 350 data yang terdiri dari masing-masing kelas kategori digunakan sebagai

data latih, dan sisanya sebanyak 150 data digunakan sebagai data uji. Selanjutnya, citra dianalisis dengan membandingkan jarak terdekat antara data uji dengan k tetangga terdekatnya dalam data latih menggunakan metode K-NN. Output dari hasil pengujian berupa kategori kelas yang direpresentasikan dalam varietas, kadar air dan harga jagung.



Gambar 3.6 Tahapan analisis citra

3.4.9 Analisis performansi sistem

Performansi sistem dinilai melalui perhitungan nilai akurasi dan tingkat *error*. K-NN merupakan metode klasifikasi, sehingga perhitungan akurasi dan *error* lebih cocok apabila menggunakan metode *misclassification rate* seperti *confusion matrix* atau *cross validation*. Pada penelitian ini, pengukuran performansi sistem menggunakan tabel *confusion matrix*. *Confusion matrix*

merupakan sebuah matrik dari hasil prediksi yang dibandingkan dengan kelas asli dari data uji. Perhitungan akurasi dilakukan untuk mengevaluasi model klasifikasi berdasar pada proporsi antara data uji yang diprediksi secara tepat dengan total seluruh prediksi. Nilai *error* menunjukkan tingkat kesalahan algoritma KNN dalam mengklasifikasikan kategori mutu jagung. Perhitungan akurasi menggunakan persamaan 3.1.

$$\text{Akurasi} = \frac{\text{jumlah pengujian data uji yang tepat}}{\text{total pengujian data uji}} \times 100\% \quad \dots (3.1)$$

Evaluasi hasil pengujian juga dilihat dengan menghitung nilai tingkat *error*. Tingkat *error* merupakan ukuran yang digunakan untuk membandingkan data yang terklasifikasikan salah dengan total data yang diprediksi. Semakin kecil nilai *error* atau mendekati 0, maka semakin baik. Secara matematis, perhitungan tingkat *error* ditunjukkan pada persamaan 3.2.

$$\text{Tingkat } error = \frac{\text{jumlah pengujian data uji yang salah}}{\text{total pengujian data uji}} \quad \dots (3.2)$$

3.4.10 Kesimpulan dan saran

Berdasarkan hasil pengolahan data dan pembahasan, dapat ditarik kesimpulan dan pemberian saran. Kesimpulan pada dasarnya menjawab permasalahan atau tujuan penelitian yang telah ditetapkan sebelumnya. Saran berisi masukan yang diharapkan dapat bermanfaat bagi pihak terkait yang membutuhkan maupun penelitian selanjutnya.



BAB IV HASIL DAN PEMBAHASAN

4.1. Implementasi Perangkat Pengambilan Citra

Perangkat pengambilan citra hasil rancangan terdiri dari laptop, kamera handphone 8MP, lampu dan kabel USB. Berdasarkan hasil percobaan dengan menggunakan dua lampu LED 5 watt dengan kamera tanpa *flash* memberikan kualitas citra lebih baik dibanding menggunakan *flash*. Hal ini karena pada saat menggunakan *flash*, cahaya tersebut memantul dan menimbulkan bayangan pada objek. Pada pemilihan warna latar objek, telah dilakukan beberapa percobaan menggunakan *background* warna putih, biru muda dan biru tua. Dari hasil percobaan, dipilih *background* warna biru tua karena memberikan warna lebih kontras terhadap warna jagung (dapat membedakan warna objek dan *background* dengan jelas) dibandingkan warna putih dan biru muda. Pada penentuan jarak antara lensa kamera dengan objek, telah dilakukan percobaan menggunakan jarak ± 12 , ± 15 dan ± 18 . Jarak terbaik yang dipilih adalah ± 12 cm. Pada jarak tersebut kondisi kamera memberikan fokus yang paling baik dan tidak kabur. Selain itu, jarak pengambilan citra juga ditentukan dengan mempertimbangkan luas obyek yang diambil. Objek ditebar pada luasan 10×10 cm dengan massa objek ± 20 gram. Penggunaan sampel jagung ± 20 gram mempertimbangkan luasan objek dan jarak kamera dengan objek.

Tahap awal sebelum dilakukan pengambilan citra, yakni menyiapkan sampel jagung pipilan basah, setengah kering dan kering untuk diuji kadar airnya. Pengujian kadar air menggunakan *moisture tester* hingga diperoleh sampel sesuai kategori mutu PERMENDAGRI No. 27/M-DAG/PER/5/2017. Adapun rincian Kategori 1 (Pertiwi 3, kadar air maksimal 15%), Kategori 2 (Pertiwi 3, kadar air maksimal 20%), Kategori 3 (Pertiwi 3, kadar air maksimal 25%), Kategori 4 (Pertiwi 3, kadar air maksimal 30%), Kategori 5 (Pertiwi 3, kadar air maksimal 35%), Kategori 6 (Pertiwi 6, kadar air maksimal 15%), Kategori 7 (Pertiwi 6, kadar air maksimal 20%), Kategori 8 (Pertiwi 6, kadar

air maksimal 25%), Kategori 9 (Pertiwi 6, kadar air maksimal 30%), Kategori 10 (Pertiwi 6, kadar air maksimal 35%).

Langkah-langkah pengambilan citra yaitu meletakkan sampel jagung di atas kertas berwarna biru tua, posisi kamera tegak lurus dengan objek pada ketinggian ± 12 cm dan menggunakan lampu LED 5 watt di atas kedua sisi objek. Selanjutnya kotak citra ditutup untuk memfokuskan cahaya agar citra tidak dipengaruhi cahaya lain, lalu dilakukan pengambilan citra. Ilustrasi pengambilan citra dapat dilihat pada **Gambar 4.1**. Pengambilan citra dilakukan dengan menyusun biji jagung sejumlah ± 20 gram untuk masing-masing kategori mutu jagung yang terdiri dari biji utuh dan campuran masing-masing biji rusak, pecah dan berjamur maks 0,4 gram (2% dari total massa sampel jagung yang digunakan). Setiap satu kategori mutu terdiri dari 5 variasi kadar air yang diambil citranya sebanyak 10 kali dengan mengacak posisi butir, sehingga menghasilkan citra yang berbeda. Total citra jagung yang diperoleh adalah 500 data. Sebanyak 350 citra digunakan sebagai data latih dan 150 citra digunakan sebagai data uji. Hasil pengambilan citra disimpan dalam format JPEG. Berkas citra selanjutnya ditransfer ke laptop menggunakan kabel USB.



Gambar 4.1 Ilustrasi pengambilan citra


4.2. Pengembangan Algoritma Pengolahan Citra

Sistem identifikasi mutu jagung terdiri dari tiga tahapan utama yaitu *preprocessing*, ekstraksi fitur dan klasifikasi. Sampel diolah sistem dan hasilnya berupa klasifikasi kategori

mutu, varietas, kadar air dan harga jagung. Tahapan pengembangan algoritma pengolahan citra pada sistem identifikasi mutu jagung dimulai dari pembacaan *image*, *resize image*, ekstraksi fitur dan tahap klasifikasi menggunakan algoritma K-NN.

4.2.1 Pembacaan *image* dan *resizing image*

Pembacaan *image* dilakukan agar dapat memproses suatu citra. Jenis file yang digunakan pada sistem identifikasi mutu jagung ini memiliki format gambar JPEG. Citra yang diinput ke dalam sistem merupakan citra hasil akuisisi yang sudah mengalami proses *cropping*. Input berupa citra jagung dapat dilihat pada **Lampiran 1**. Proses *cropping* pada citra asli hasil akuisisi bertujuan untuk memotong citra pada bagian yang tidak diperlukan, sehingga didapatkan hasil yang diinginkan untuk mempermudah data yang diolah. Proses *cropping* dilakukan sesuai dengan luasan objek dengan bantuan *Microsoft Office Picture Manager*. Citra sebelum dan sesudah *cropping* dapat dilihat pada **Gambar 4.2 (a)** dan **Gambar 4.2 (b)**. Tahap *resizing* bertujuan untuk mengubah ukuran citra hasil *cropping* menjadi citra yang diproses. Proses *resizing* dilakukan agar citra yang diekstrak memiliki ukuran piksel yang sama dan meringankan beban kinerja sistem dalam melakukan proses identifikasi mutu jagung. Citra hasil *cropping* berukuran 1660x1660 piksel di-*resize* menjadi 300x300 piksel untuk meringankan kinerja sistem. Citra hasil *resizing* ditunjukkan pada **Gambar 4.2 (c)**.




Gambar 4.2 (a) Citra sebelum *cropping*, **(b)** citra hasil *cropping*, **(c)** citra hasil *resizing*

4.2.2 Ekstraksi fitur

Ekstraksi fitur dilakukan untuk mendapatkan fitur dari biji jagung. Pada penelitian ini, citra biji jagung diidentifikasi berdasarkan fitur warna dan fitur tekstur. Pada sistem, terdapat 7 parameter fitur yang digunakan yang terdiri dari fitur warna dan tekstur. Ekstraksi fitur warna menggunakan komponen H, S, V, sedangkan ekstraksi fitur tekstur menggunakan *Gray Level Co-occurrence Matrix* (GLCM). Fitur GLCM yang digunakan antara lain *contrast*, *correlation*, *energy*, dan *homogeneity*.

a) Ekstraksi fitur warna

Untuk mengekstrak nilai ciri H,S,V, terlebih dahulu dilakukan konversi citra RGB ke HSV. Konversi RGB ke HSV pada matlab bisa dilakukan dengan menggunakan fungsi "*rgb2hsv*". Perhitungan nilai *mean* (*color moment*) HSV dilakukan dengan mengambil nilai dari setiap komponen H, S, V, kemudian dihitung nilai *mean*-nya menggunakan fungsi matlab "*mean2*". Nilai *mean* atau piksel rata-rata merupakan suatu nilai yang menunjukkan ukuran dispersi dari suatu citra. Citra hasil ekstraksi komponen HSV dapat dilihat pada **Gambar 4.3**.




Gambar 4.3 (a) Ekstraksi nilai *Hue*, (b) Ekstraksi nilai *Saturation*, (c) Ekstraksi nilai *Value*

b) Ekstraksi fitur tekstur

Tahapan pada ekstraksi fitur tekstur dimulai dengan mengubah citra hasil *resize* menjadi citra *grayscale*. Citra *grayscale* kemudian diproses melalui tahapan *preprocessing* atau perbaikan kualitas citra dengan *image enhancement* dan

median filtering. *Image enhancement* berfungsi untuk meningkatkan fitur tertentu pada citra, sehingga tingkat keberhasilan proses pengolahan citra selanjutnya menjadi lebih tinggi. Teknik yang digunakan adalah *intensity adjustment (imadjust)* untuk mendapatkan kontras baru yang lebih baik dari citra asal. *Median filtering* digunakan untuk menghilangkan derau pada citra hasil *imadjust*. Tahapan setelah *preprocessing* yaitu segmentasi, dimana pada tahap ini citra diklasifikasikan menjadi beberapa daerah atau *region* yang memiliki karakteristik yang sama. Metode yang digunakan adalah *thresholding*. *Thresholding* berfungsi untuk memisahkan antara objek dengan *background* berdasarkan perbedaan tingkat kecerahannya. *Region* citra yang cenderung gelap dibuat semakin gelap (hitam sempurna), sedangkan *region* citra yang cenderung terang dibuat semakin terang (putih sempurna). Nilai *Threshold* yang digunakan yaitu 130, nilai ini diperoleh melalui *trial error* hingga bagian objek dan *background* dapat dipisahkan secara sempurna. Pada kasus biji berjamur memiliki warna cenderung gelap, sehingga saat tersegmentasi, biji berubah warna menjadi hitam (hilang). Hasil dari proses *thresholding* berupa citra biner dengan nilai intensitas piksel sebesar 0 (*background*) atau 1 (objek) yang ditunjukkan pada **Gambar 4.4 (a)**.



Gambar 4.4 (a) Citra *biner*, **(b)** Citra RGB hasil segmentasi, **(c)** Citra *grayscale*

Tahapan proses berikutnya, citra biner hasil segmentasi kemudian disatukan kembali dengan objek asli sehingga menghasilkan citra warna tanpa *background*. Citra RGB hasil segmentasi dapat dilihat pada **Gambar 4.4 (b)**. Ekstraksi fitur

citra berdasarkan analisis tekstur GLCM hanya bisa dilakukan pada citra *grayscale*, sehingga citra RGB hasil segmentasi diubah menjadi *grayscale* untuk selanjutnya dianalisis fiturnya. Sebelum mengubah citra RGB menjadi *grayscale*, perlu dilakukan konversi RGB dari kelas *uint8* menjadi kelas *double* menggunakan perintah `"im2double"`. Menurut Phivin dan Subhajini (2017), citra *grayscale* masih bertipe *uint8*, dimana *array*-nya tidak dapat diproses dengan operator matematika seperti penjumlahan, pengurangan maupun operasi lainnya, sehingga harus dikonversi terlebih dahulu dari kelas *uint* menjadi kelas *double*. Fitur GLCM yang diekstrak nilainya antara lain *contrast*, *correlation*, *energy*, dan *homogeneity*. Perhitungan nilai dari masing-masing fitur GLCM dilakukan otomatis oleh sistem. Citra *grayscale* hasil konversi citra RGB ditunjukkan pada **Gambar 4.4 (c)**. *Source code* ekstraksi fitur warna HSV dan fitur tekstur dapat dilihat pada **Lampiran 2**, sedangkan nilai hasil ekstraksi fitur warna HSV dan fitur tekstur dapat dilihat pada **Lampiran 3**.

4.2.3 Klasifikasi algoritma K-NN

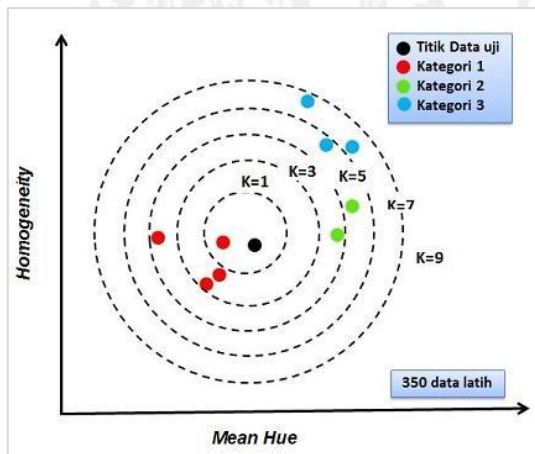
Pada proses klasifikasi K-NN, citra uji yang telah diolah melalui tahap pengolahan citra diklasifikasikan berdasarkan kategori kelas yang ditentukan. Konsep klasifikasi K-NN adalah mengklasifikasikan data berdasarkan jumlah tetangga (nilai k) dan kedekatan jarak antara fitur data uji dengan fitur data latih. Semakin kecil nilai jarak antara dua vektor tersebut maka semakin dekat atau semakin mirip. Berikut contoh perhitungan manual algoritma *K-Nearest Neighbor* (K-NN) pada sistem klasifikasi jagung menggunakan salah satu data uji dengan nilai fitur yang ditunjukkan pada **Tabel 4.1**.

Tabel 4.1 Contoh nilai fitur data uji

Data Uji	H	S	V	Con	Cor	Eng	Hom
1	0,2796	0,6723	0,6565	0,5738	0,9398	0,2110	0,9043

Sumber : Data yang diolah (2018)

Berdasar data uji pada **Tabel 4.1**, maka dapat dilakukan perhitungan jarak fitur data uji tersebut terhadap fitur data latih. Nilai vektor fitur data latih yang digunakan dalam perhitungan dapat dilihat pada **Lampiran 3(a)**. Pada algoritma K-NN, data latih sejumlah 350 citra diproyeksikan ke dalam ruang berdimensi banyak (ditunjukkan **Lampiran 4**), dimana masing-masing dimensi mempresentasikan fitur data yakni *Mean Hue*, *Mean Saturation*, *Mean Value*, *Contrast*, *Correlation*, *Energy*, dan *Homogeneity*. Ruang tersebut terbagi menjadi bagian-bagian berdasarkan klasifikasi data latih, dalam hal ini terdapat 10 kelas kategori. Visualisasi K-NN dengan 9 tetangga terdekat dari seluruh data latih menggunakan jarak *euclidean* dapat dilihat pada **Lampiran 5**.



Gambar 4.5 Ilustrasi hasil klasifikasi K-NN menggunakan $k = 9$ pada fitur *Mean Hue* dan *Homogeneity*

Ilustrasi klasifikasi K-NN yaitu data uji pada **Tabel 4.1** yang belum diketahui kelasnya digambarkan sebagai titik *query* berwarna hitam, sedang titik-titik data latih diasumsikan merupakan titik temu dari ketujuh dimensi fitur. Karena dimensi dan jumlah data terlalu besar, maka diambil contoh titik temu fitur *Mean Hue* dan *Homogeneity* (**Lampiran 5**) yang ditunjukkan pada **Gambar 4.5**. Titik data uji selanjutnya dihitung

jaraknya terhadap keseluruhan data latih, kemudian dipilih nilai jarak terkecil sebanyak jumlah tetangga yang ditentukan. Penentuan kelas didasarkan voting mayoritas dari sejumlah k obyek (data latih) yang paling dekat dengan titik *query*. Pada nilai k=9, artinya dari 350 data latih, diambil 9 data yang memiliki jarak terdekat dengan data uji, demikian halnya dengan nilai k=1,3,5 dan 7. **Gambar 4.5** menunjukkan saat menggunakan nilai k=1,3,5,7 maupun 9, data uji terklasifikasikan kedalam kategori 1, karena jumlah mayoritas kelas pada tetangga terdekat 1,3,5,7 dan 9 adalah kategori 1. Pada contoh perhitungan manual K-NN, nilai k yang digunakan yaitu 9. Hasil dari perhitungan jarak antara data uji pada **Tabel 4.1** dengan keseluruhan data latih dapat dilihat pada **Lampiran 6**. Contoh perhitungan jarak *Euclidean* antara data uji tersebut dan data latih ke-1 pada **Lampiran 3(a)** sebagai berikut:

$$d(x, y) = \sqrt{\sum_{k=1}^n (x_i - y_i)^2}$$

$$d(x, y) = \sqrt{(0,2773 - 0,2796)^2 + (0,6655 - 0,6723)^2 + (0,6468 - 0,6565)^2 + (0,6089 - 0,5738)^2 + (0,9372 - 0,9398)^2 + (0,2094 - 0,2110)^2 + (0,9002 - 0,9043)^2}$$

$$= 0,0375$$

Hasil perhitungan jarak *Cityblock* data uji **Tabel 4.1** terhadap seluruh data latih ditunjukkan **Lampiran 7**. Berikut merupakan contoh perhitungan data uji tersebut dengan data latih ke-1 pada **Lampiran 3(a)** menggunakan *Cityblock distance*:

$$d(x, y) = \sum_i^n \|x_i - y_i\|$$

$$d(x, y) = (0,2773 - 0,2796) + (0,6655 - 0,6723) + (0,6468 - 0,6565) + (0,6089 - 0,5738) + (0,9372 - 0,9398) + (0,2094 - 0,2110) + (0,9002 - 0,9043)$$

$$= 0,0079$$

Berdasarkan perhitungan jarak data uji tersebut dengan seluruh data latih, diambil 9 tetangga terdekat yang memiliki nilai jarak terkecil. Penentuan tetangga terdekat dapat dilihat pada **Lampiran 8**. Berdasarkan metode *Euclidean*, data uji tersebut memiliki jarak terdekat dengan empat data berlabel Kategori 1, dua data berlabel Kategori 2, dan tiga data berlabel Kategori 3. Penentuan label kelas data uji pada klasifikasi K-NN dengan melakukan voting berdasar jumlah kelas terbanyak yang diperoleh diantara 9 data latih terdekat tersebut, sehingga dapat disimpulkan bahwa data uji tersebut termasuk dalam Kategori 1. Demikian pula pada perhitungan jarak *Cityblock*, data uji tersebut dikategorikan ke dalam Kategori 1, karena voting kelas terbanyak terdapat pada Kategori 1. Penentuan kelas dapat dilihat pada **Lampiran 9**, sedang penentuan kelas keseluruhan data uji berdasarkan jarak *Euclidean* dan *Cityblock* menggunakan jumlah tetangga $k = 1, 3, 5$, dan 7 dihitung dengan cara yang sama seperti contoh yang telah dijelaskan.

4.3. Implementasi GUI (Antarmuka Sistem)

Sistem identifikasi mutu jagung dirancang menggunakan tampilan *Graphical User Interface*, sehingga tampil lebih menarik dan mudah dioperasikan. Aplikasi yang dibuat menggunakan bahasa pemrograman Matlab R2012a dan berbasis algoritma KNN. Halaman utama atau beranda menampilkan informasi nama aplikasi yang dibuat yaitu SIMURNI yang merupakan akronim dari Sistem Identifikasi Mutu dan Harga Jagung di Tingkat Petani. Adapun tampilan setiap menu yang terdapat pada aplikasi ini sebagai berikut:

a. Beranda aplikasi

Pada beranda aplikasi, terdapat empat menu yang dapat dipilih *user* sesuai kebutuhan. Pada setiap menu terdapat beberapa sub-menu yang dapat dipilih oleh *user*. Menu tersebut digunakan untuk masuk ke menu yang ada didalam aplikasi yaitu menu *file*, menu *help*, menu *about* dan *exit*. Beberapa menu memiliki sub-menu yang berbeda-beda. **Gambar 4.6** merupakan tampilan beranda aplikasi.



Gambar 4.6 Beranda aplikasi

Tampilan isi menu *file* ditunjukkan oleh **Gambar 4.7**. Menu *file* berisi program utama untuk identifikasi mutu dan varietas jagung. Menu ini terdiri dari sub menu identifikasi mutu untuk *end user* dan detail proses identifikasi. **Gambar 4.8** menunjukkan isi menu *help* yang terdiri dari sub-menu tentang mutu dan tentang aplikasi. Adapun tampilan kotak dialog keluar dari aplikasi dapat dilihat pada **Gambar 4.9**.



Gambar 4.7 Isi menu *file* pada beranda aplikasi



Gambar 4.8 Isi menu *about* pada beranda aplikasi



Gambar 4.9 Kotak dialog keluar beranda aplikasi

b. Menu *file*

Menu *file* terdiri dari sub menu identifikasi mutu jagung untuk *end user* dan detail proses identifikasi. Menu ini merupakan bagian utama dari aplikasi yang dibuat. Sub menu identifikasi mutu jagung untuk *end user* didesain sedemikian ringkas untuk memudahkan pengguna dalam mengaplikasikan sistem yang dibuat.



Gambar 4.10 Tampilan identifikasi mutu jagung (*end user*)

Sub menu detail proses menampilkan tahapan identifikasi secara detail. Pada sub menu ini, user memilih citra masukan yang ingin diketahui mutu dan varietasnya, selanjutnya sistem melakukan klasifikasi untuk menentukan kelas dari data yang diinput. Proses klasifikasi K-NN menggunakan *default* nilai $k=5$ dan metode *Cityblock distance*, hal ini berdasar hasil pengujian


terbaik. Tampilan sub menu identifikasi mutu jagung untuk *end user* dan detail proses beserta bagian-bagiannya ditunjukkan pada **Gambar 4.10** dan **Gambar 4.11**.



Gambar 4.11 Tampilan detail proses identifikasi

Pada **Gambar 4.10** dan **Gambar 4.11**, Bagian 1 menunjukkan *outline user*. Tombol pengambilan citra berfungsi menginput *file* citra jagung untuk diidentifikasi mutunya. Adapun tampilan pada saat *user* melakukan pengambilan citra ditunjukkan pada **Gambar 4.12**. Tombol ekstraksi ciri digunakan untuk mengekstrak fitur warna HSV dan tekstur GLCM, Tombol identifikasi berfungsi untuk menghitung kedekatan jarak citra uji dengan data latih berdasarkan jumlah *k* dan jarak yang dipilih *user*. Tombol *reset* digunakan untuk mengembalikan program identifikasi mutu jagung seperti kondisi awal sebelum pengambilan citra uji dimulai. Bagian 2 menunjukkan tampilan citra uji yang dipilih *user*. Bagian 3 menunjukkan gambar dan nilai fitur ekstraksi warna H, S, V dan tekstur GLCM yaitu *contrast*, *correlation*, *energy* dan *homogeneity*. Bagian 4 menunjukkan pemilihan aturan klasifikasi menggunakan K-NN, dimana *user* harus memilih nilai *k* dan metode jarak yang digunakan untuk proses klasifikasi. Bagian 5 menunjukkan hasil

dari klasifikasi K-NN. Output yang dihasilkan berupa varietas, kadar air dan harga jagung.



Gambar 4.12 Tampilan pengambilan citra uji

c. Menu *Help*

Menu *help* berisi tentang petunjuk penggunaan aplikasi. Pada menu ini, *user* dapat membaca panduan dan langkah-langkah dalam menjalankan aplikasi untuk identifikasi mutu jagung. Menu *help* membantu mempermudah *user* memahami tahapan-tahapan dalam melakukan proses identifikasi mutu jagung. Tampilan menu *help* tentang petunjuk penggunaan aplikasi ditunjukkan pada Gambar 4.13 dan Lampiran 10.



Gambar 4.13 Tampilan menu *help*

d. Menu *About*

Menu *about* terdiri dari dua sub menu yaitu sub menu tentang mutu jagung dan tentang aplikasi yang dibuat. Pada sub menu tentang mutu jagung berisi informasi yang menjelaskan secara singkat mengenai standar mutu yang dijadikan acuan dalam pembuatan program aplikasi ini. Pada sub menu tentang aplikasi berisi informasi mengenai penjelasan singkat kegunaan dari aplikasi yang dibuat. Tampilan sub menu tentang mutu jagung dan tentang aplikasi dapat dilihat pada **Gambar 4.14**.



Gambar 4.14 (a) Tampilan tentang mutu jagung, (b) Tampilan tentang aplikasi

4.4. Pelatihan dan Pengujian Sistem

Proses pelatihan sistem dilakukan untuk melatih algoritma K-NN agar mampu mengidentifikasi mutu jagung. K-NN membangun sistem klasifikasi melalui pembelajaran dari sejumlah data latih yang sudah diklasifikasikan sebelumnya. Pada metode K-NN, proses pelatihan tidak membentuk model sebagaimana algoritma *supervised learning* lainnya. Menurut Kim (2012), proses pelatihan pada algoritma K-NN hanya terdiri dari penyimpanan vektor fitur dan label dari citra latih, sehingga

algoritma ini tidak menggunakan model apapun untuk dicocokkan dan hanya berdasarkan pada memori (Liantoni, 2015). K-NN bersifat *lazy learner*, dimana proses pembelajarannya menunggu hingga menit terakhir sebelum model dibangun dibutuhkan untuk mengklasifikasikan data uji. Berbeda dengan *eager learner*, algoritma *lazy learner* menyimpan data pelatihan dan menunggu hingga diberikan data uji sehingga metode ini bekerja lebih sedikit ketika proses pelatihan dan bekerja lebih banyak ketika proses pengujian.

Pada kasus identifikasi mutu dan varietas jagung, proses pelatihan algoritma K-NN dilakukan dengan menyimpan vektor fitur warna HSV dan fitur tekstur GLCM serta label kelas dari masing-masing kategori mutu. Data hasil ekstraksi 3 fitur warna dan 4 fitur tekstur jagung yang merupakan parameter uji disimpan dalam direktori matlab dalam bentuk *file.mat*. Jumlah data citra yang digunakan yaitu 500 citra jagung, dimana data terbagi menjadi data latih dan data uji dengan rasio perbandingan 70% data latih dan 30% data uji. *Database* citra latih yang ditanam pada sistem ini sejumlah 350 data. *Database* tersebut nantinya dijadikan sebagai acuan dalam proses pengujian sistem.

Pengujian sistem bertujuan untuk mengetahui kemampuan sistem dalam memprediksi ketepatan identifikasi mutu jagung berdasarkan fitur warna HSV dan fitur tekstur GLCM. Jumlah data uji yaitu 150 data yang terdiri dari 15 data untuk masing-masing Kategori 1 sampai dengan Kategori 10. 15 data tersebut diambil secara acak sebanyak 3 data per kelompok varasi kadar air dari tiap kategori. Pengujian berfokus pada akurasi hasil klasifikasi yang dilakukan oleh program. Pada pengujian sistem dilakukan dengan memberikan variasi nilai k dan metode perhitungan jarak. Selanjutnya dilakukan perhitungan akurasinya. *Source code* proses pelatihan dan pengujian dapat dilihat pada **Lampiran 11**, sedang hasil proses klasifikasi mutu jagung menggunakan variasi nilai k dan jarak *Euclidean* dan *Cityblock* dapat dilihat pada **Lampiran 12**. Secara keseluruhan, hasil yang terklasifikasikan dengan benar menggunakan K-NN ditunjukkan pada **Tabel 4.2**.

Tabel 4.2 Hasil klasifikasi benar menggunakan *K-Nearest Neighbor*

k	Jumlah Data Benar										Total Benar	Akurasi (%)
	K1	K2	K3	K4	K5	K6	K7	K8	K9	K10		
<i>Metode Euclidean</i>												
1	13	10	11	13	12	15	14	8	14	15	125	83,33
3	14	10	9	12	12	15	15	10	14	15	126	84,00
5	14	10	13	11	12	15	14	7	13	15	124	82,67
7	14	9	13	10	14	14	13	9	15	15	126	84,00
9	14	10	14	11	10	14	15	9	14	14	125	83,33
<i>Metode Cityblock</i>												
1	12	10	13	12	13	15	14	10	15	15	129	86,00
3	14	10	12	11	14	15	15	11	14	15	131	87,33
5	14	11	14	12	14	15	15	10	15	15	135	90,00
7	13	11	14	9	14	15	15	13	15	15	134	89,33
9	14	10	13	12	11	14	15	10	15	14	128	85,33

Sumber : Data yang diolah (2018)

Keterangan :

- K1 : Pertiwi 3 dengan kriteria Kadar air maks 15%, harga Rp.3.150,-/kg
- K2 : Pertiwi 3 dengan kriteria Kadar air maks 20%, harga Rp.3.050,-/kg
- K3 : Pertiwi 3 dengan kriteria Kadar air maks 25%, harga Rp.2.850,-/kg
- K4 : Pertiwi 3 dengan kriteria Kadar air maks 30%, harga Rp.2.750,-/kg
- K5 : Pertiwi 3 dengan kriteria Kadar air maks 35%, harga Rp.2.500,-/kg
- K6 : Pertiwi 6 dengan kriteria Kadar air maks 15%, harga Rp.3.150,-/kg
- K7 : Pertiwi 6 dengan kriteria Kadar air maks 20%, harga Rp.3.050,-/kg
- K8 : Pertiwi 6 dengan kriteria Kadar air maks 25%, harga Rp.2.850,-/kg
- K9 : Pertiwi 6 dengan kriteria Kadar air maks 30%, harga Rp.2.750,-/kg
- K10 : Pertiwi 6 dengan kriteria Kadar air maks 35%, harga Rp.2.500,-/kg

Pada **Tabel 4.2** dapat dilihat hasil klasifikasi sistem menggunakan K-NN tiap variasi nilai k dan metode perhitungan jarak yang digunakan. Pada sistem ini, hasil akurasi tertinggi didapatkan ketika menggunakan metode *Cityblock distance* dengan nilai k=5 yaitu sebesar 90,00%. Nilai k = 5 berarti terdapat lima vektor berdekatan yang digunakan sebagai pembandingan terhadap data uji, dengan nilai tersebut maka sudah dapat mewakili vektor fitur dari berbagai kelas. Dari total 150 data uji, sistem mampu mengklasifikasikan mutu jagung dengan benar sebanyak 135 data, sedang data yang terdeteksi salah sebanyak 15 data. Akurasi terendah didapatkan ketika menggunakan *Euclidean* dengan nilai k=5, yaitu sebesar 82,67%, dimana data yang terklasifikasi benar sebanyak 124 data, sedangkan data yang terdeteksi salah sebanyak 26 data.


Berdasar hasil akurasi K-NN terbaik, sistem mampu mengklasifikasikan semua data dengan benar pada Kategori 6, Kategori 7, Kategori 9 dan Kategori 10. Data yang paling sedikit terklasifikasikan dengan benar yaitu Kategori 8. Citra yang tidak terklasifikasikan dengan benar dapat dipengaruhi oleh beberapa faktor antara lain faktor cahaya, kotoran pada objek dan kondisi kamera yang kurang fokus pada saat proses pengambilan citra, sehingga citra yang dihasilkan memiliki lebih banyak *noise* dan sulit dikenali oleh sistem. Menurut Sela dan Muhammad (2017), proses pengambilan citra mempengaruhi hasil akurasi yang dihasilkan dari sistem. Proses *capture* yang tidak sempurna, pencahayaan yang kurang merata atau adanya kotoran yang menempel pada citra dapat mengakibatkan kualitas citra hasil *capture* rendah mengakibatkan objek sulit dipisahkan dari *background*-nya, sehingga citra sulit diinterpretasikan karena informasi yang disampaikan oleh citra berkurang (Dasopang, 2015).



Gambar 4.15 Contoh tampilan hasil identifikasi mutu (*end user*)

Proses pengujian sistem juga dilakukan melalui tampilan GUI. Proses pengujian berbasis GUI ditujukan untuk mempermudah *user* dalam mengaplikasikan program identifikasi mutu jagung. Terdapat dua jenis tampilan identifikasi mutu, pertama tampilan yang didesain untuk *end user* dan

kedua menampilkan detail tahapan proses identifikasi secara lebih rinci. Tampilan hasil identifikasi mutu jagung untuk *end user* ditunjukkan **Gambar 4.15**. Pada identifikasi mutu untuk *end user*, proses klasifikasi dilakukan secara otomatis oleh sistem menggunakan K-NN dengan nilai *default* $k=5$ dan *Cityblock distance*. Langkah pertama menjalankan sistem, *user* dapat mengambil citra jagung untuk diidentifikasi mutunya dengan memilih tombol “Ambil citra”. Selanjutnya mengklik tombol “Identifikasi” untuk memunculkan hasil klasifikasi. Tombol “Reset” berfungsi untuk mengembalikan keadaan seperti semula.



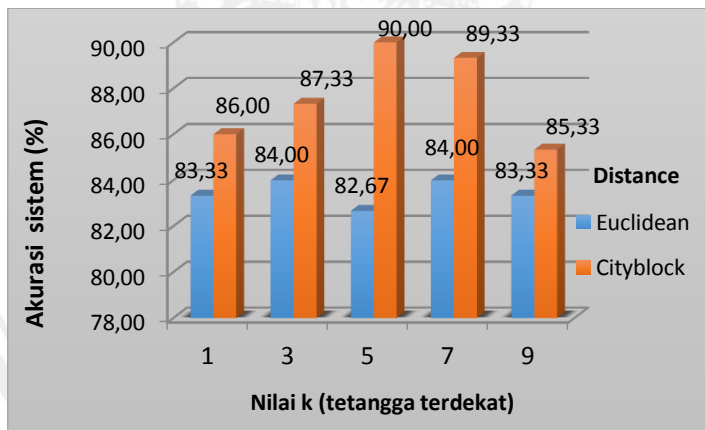
Gambar 4.16 Contoh tampilan hasil detail proses identifikasi

Gambar 4.16 menunjukkan tampilan hasil identifikasi mutu jagung secara detail. Detail proses identifikasi merupakan gabungan dari tahapan pengolahan citra mulai dari tahap pengambilan citra, *preprocessing*, ekstraksi fitur dan klasifikasi mutu jagung. Pada tahap ini, *user* dapat memulai dengan mengambil citra yang ingin diidentifikasi mutunya dengan memilih tombol “Ambil citra”. Selanjutnya mengklik tombol “Ekstraksi ciri”, maka diperoleh nilai fitur warna HSV dan fitur tekstur GLCM yang dijadikan sebagai parameter uji kemiripan

dengan data latih. Tahap berikutnya, *user* dapat memilih nilai *k* tetangga terdekat dan metode jarak perhitungan untuk klasifikasi K-NN. Tahap terakhir yaitu mengklik tombol “Identifikasi”, maka sistem melakukan proses klasifikasi K-NN dengan menghitung kemiripan antara vektor fitur citra yang diuji dengan vektor fitur citra data latih yang sudah tertanam dalam *database* sistem berdasarkan nilai *k* dan metode *distance* yang dipilih oleh *user* pada tahap sebelumnya. Setelah melakukan identifikasi, maka sistem memunculkan *output* berupa varietas, kadar air dan harga.

4.5. Analisis Performansi Sistem

Performansi sistem dinilai dengan menghitung nilai akurasi dan *error* sistem menggunakan *Confusion matrix*. Perbandingan tingkat akurasi algoritma K-NN dalam mengidentifikasi mutu jagung menggunakan variasi nilai *k* dan metode *Euclidean* dan *Cityblock* ditunjukkan pada **Gambar 4.17**.



Gambar 4.17 Perbandingan tingkat akurasi pada variasi nilai *k* dan *distance*

Berdasar **Gambar 4.17** dapat disimpulkan bahwa hasil klasifikasi dengan nilai $k=5$ menggunakan metode *Cityblock*,

sistem mampu mendeteksi kategori benar dengan akurasi tertinggi sebesar 90,00% dan tingkat *error* terendah sebesar 0,1. Menurut Prasetyo (2012), *Cityblock* memiliki kemampuan tangguh dalam mendeteksi *outlier* (data pencilan) berbasis jarak. Hal ini disebabkan *Cityblock distance* menggunakan selisih jumlah absolut antara dua data, sehingga mampu memberikan jarak terjauh antara dua data tersebut. Hasil perhitungan akurasi klasifikasi K-NN terhadap 150 data uji menggunakan *confusion matrix* dengan hasil terbaik menggunakan nilai k=5 dan metode *Cityblock* dapat dilihat pada **Lampiran 13**. Berdasarkan hasil tabel *confusion matrix* hasil klasifikasi terbaik, berikut perhitungan akurasi dan tingkat *error* algoritma K-NN :

a. Akurasi dihitung menggunakan persamaan 3.1)

$$\text{Akurasi} = \frac{\text{jumlah pengujian data uji yang tepat}}{\text{total pengujian data uji}} \times 100\%$$

$$\text{Akurasi} = \frac{14 + 11 + 14 + 12 + 14 + 15 + 15 + 10 + 15 + 15}{150} \times 100\%$$

$$= 90,00\%$$

b. Nilai *error* dihitung menggunakan persamaan 3.2)

$$\text{Tingkat error} = \frac{\text{jumlah pengujian data uji yang salah}}{\text{total pengujian data uji}}$$

$$\text{Tingkat error} = \frac{1 + 4 + 1 + 3 + 1 + 0 + 0 + 5 + 0 + 0}{150}$$

$$= 0,1$$

BAB V KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan hasil analisis sistem identifikasi mutu jagung, dapat ditarik kesimpulan sebagai berikut:

- 1) Perancangan dan implementasi sistem identifikasi mutu jagung berbasis pengolahan citra digital telah berhasil dilakukan menggunakan input warna HSV dan fitur tekstur GLCM yang terdiri dari *contrast*, *correlation*, *energy*, dan *homogeneity*. Sistem dirancang melalui tahapan akuisisi citra, pengembangan algoritma pengolahan citra yang terdiri dari *preprocessing*, ekstraksi fitur dan klasifikasi K-NN, serta tahapan implementasi dalam bentuk GUI aplikasi. Berdasarkan hasil uji, aplikasi yang dibuat mampu menggolongkan mutu dan varietas jagung menjadi 10 kategori yang terdiri dari Pertiwi 3 dan Pertiwi 6 masing-masing 5 Kategori mutu, serta menghasilkan *output* lain seperti kadar air dan harga beli jagung.
- 2) Metode *K-Nearest Neighbor* (K-NN) mampu mengidentifikasi mutu dan varietas jagung di tingkat petani serta menghasilkan akurasi yang baik. Akurasi tertinggi diperoleh saat nilai $k=5$ menggunakan *Cityblock distance* dengan nilai akurasi sebesar 90,00%

5.2. Saran

Untuk penelitian selanjutnya, dapat menggunakan parameter lain yang memiliki pengaruh baik dalam mengenali karakteristik fitur jagung untuk meningkatkan akurasi sistem identifikasi mutu dan varietas jagung, seperti menambahkan fitur bentuk sebagai parameter uji dan menambah varietas jagung. Selain itu, dapat mengembangkan sistem yang mampu melakukan pendugaan massa terhadap biji rusak, berjamur, pecah, serta mampu mengidentifikasi kadar air dan harga jagung secara *real time*.



DAFTAR PUSTAKA

- Adrizal, Anggraini D., N. Novita, Santosa, Andasuryani. 2011. **Pendugaan Kualitas Fisik Biji Jagung untuk Bahan Pakan Menggunakan Jaringan Syaraf Tiruan Berdasarkan Data Citra Digital.** Jurnal Peternakan Indonesia 13(3): 183-190
- Aggarwal, N. dan R. Kajnu A. 2012. ***First and Second Order Statistics Features for Classification of Magnetic Resonance Brain Images.*** Journal of Signal and Information Processing 3: 146-153
- Ahmad, U. 2005. **Pengolahan Citra Digital dan Teknik Pemrogramannya.** Graha Ilmu. Yogyakarta.
- Aini, Nur. 2013. **Teknologi Fermentasi Pada Tepung Jagung.** Graha Ilmu. Yogyakarta
- Albregtsen, Fritz. 2008. ***Statistical Texture Measures Computed from Gray Level Cooccurrence Matrices.*** Image Processing Laboratory Department of Informatics University of Oslo. Norway
- Andono dan Pulung Nurtantio. 2015. **Konsep Pengolahan Citra Digital Ed. 1.** Andi. Yogyakarta
- Annadurai, S. and R. Shanmugalakshmi. 2007. ***Fundamentals of Digital Image Processing.*** Dorling Kindersley. Delhi
- Arifin AD. 2012. **Implementasi Algoritma *K-Nearest Neighbor* Yang Berdasarkan *One Pass Clustering* Untuk Kategorisasi Teks.** Tesis Institut Teknologi Sepuluh November. Surabaya.
- Badan Litbang Pertanian. 2015. **Harmonisasi Data Produksi Dan Konsumsi Beras Dan Jagung Dalam Kaitan Dengan**

Luas Lahan Dan Produktivitas. Badan Penelitian dan Pengembangan Pertanian. Jakarta

Biswas, D., Amitava Nag, Soumadip G., Arindrajit P., Sushanta B., and Snehasish, B. 2011. ***Novel Gray Scale Conversion Techniques Based On Pixel Depth.*** Journal of Global Research in Computer Science 2(6): 118-121

Bora, P.K., Mahadeva P., Kandarpa K.S., and Navajit S. 2015. ***Advances in Communication and Computing.*** Springer. New Delhi

BPS Provinsi Jawa Timur. 2016. **Survey Pertanian : Produksi Padi dan Palawija di Jawa Timur 2015/2016.** Badan Pusat Statistik Provinsi Jawa Timur. Surabaya

BPTP NAD. 2009. **Budidaya Tanaman Jagung.** Balai Pengkajian Teknologi Pertanian Nanggro Aceh Darusalam. Aceh

BSN. 2013. **SNI 4483-1998 Tentang Jagung Bahan Pakan Ternak.** Badan Standarisasi Nasional. Jakarta

Bustomi, M.A. dan Ahmad Zaki D. 2014. **Analisis Distribusi Intensitas RGB Citra Digital Untuk Klasifikasi Kualitas Biji Jagung Menggunakan Jaringan Syaraf Tiruan.** Jurnal Fisika dan Aplikasinya 10(3): 127-132

Chitra, S. dan Balakrishnan. 2012. ***Comparative Study for Two Color Spaces HSCbCr and YcbCr in Skin Color Detection.*** Applied Mathematical Sciences 6(85): 4229-4238.

Crisnanto, Heru. 2011. **Pengendalian Kualitas Cairan Dalam Botol Berbasis Pengolahan Citra.** Skripsi. Universitas Sebelas Maret. Surakarta

- Daryanto. 2016. **Aplikasi Pembesaran Citra Menggunakan Metode Nearest Neighbour Interpolation.** Jurnal Sistem dan Teknologi Informasi Indonesia 1(1): 31-35
- Dasopang, Massnun. 2015. **Metode Perancangan Perangkat Lunak Mereduksi Noise Citra Menggunakan Contraharmonic Mean Filter.** Jurnal Riset Komputer 6(2): 56-61
- Deswal, M. dan Neetu S. 2012. **A Fast HSV Image Color and Texture Detection and Image Conversion Algorithm.** International Journal of Science and Research 3(6): 1279-1284.
- Dey, N., Amira A., and Prasenjit K. P. 2017. **Feature Detectors and Motion Detection in Video Processing.** IGI Global. Hershey
- Dhian, Ignantia dan Kritian Adi N. 2016. **Klasifikasi Batik Menggunakan K-NN Berbasis Wavelet.** Seminar Nasional Teknologi Informasi dan Komunikasi : 615-623
- Ditjen Tanaman Pangan. 2016. **Pedoman Pelaksanaan Kegiatan 2017 : Jagung.** Direktorat Jenderal Tanaman Pangan Kementerian Pertanian. Jakarta
- DKPP. 2015. Pemerintah Perketat Impor Jagung Demi Produsen Lokal. Diakses pada tanggal 04 Mei 2017 melalui <http://dkpp.jabarprov.go.id/pemerintah-perketat-impor-jagung-demi-produsen-lokal/>
- Dzuida, D. M. **Data Mining for Genomics and Proteomics : Analysis of Gene and Protein Expression Data.** John Wiley & Sons. Chichester
- Fahmi. 2007. **Perancangan Algoritma Pengolahan Citra Mata Menjadi Citra Polar Iris Sebagai Bentuk Antara Sistem Biometrik.** Karya Ilmiah. Universitas Sumatra Utara. Medan

Gamit, C., Prashant B., Swadas, dan Nilesh B.P. 2015. ***Flower Grain Image Classification Using Supervised***. International Journal of Engineering Research and Development 11(5): 70-75.

Ganis, K.Y., Santoso, I., Isnanto, R., 2011. **Klasifikasi Citra Dengan Matriks Ko-Okurensi Aras Keabuan GLCM (Gray Level Co-Occurrence Matrix) Pada Lima Kelas Biji-Bijian**. Tesis. Universitas Diponegoro. Semarang

Gu, Qi and Zhifei S. 2009. ***Image Classification Using SVM, KNN and Performance Comparison with Logistic Regression : Final project report***. Departement of Computer Science, Dartmouth College, Hanover

Han J., Jian P. and Micheline K. 2011. ***Data Mining : Concept and Techniques 3rd Edition***. Morgan Kaufmann Publisher. Waltham

Hermawati, Fajar Astuti. 2013. **Pengolahan Citra Digital Konsep & Teori**. ANDI. Yogyakarta

Ibraheem, Noor A., Mokhtar M.H. Rafiqul Z.K. and Pramod K.M. 2012. ***Understanding Color Models : A Review***. ARPN Journal of Science and Technology 2(3): 265-275

Karyanti, Yuli. 2010. **Pencarian Citra Berdasarkan Filter Lokal Tekstur**. Disertasi Program Doktor Teknologi Informasi. Universitas Gunadarma. Depok

Kementrian Perdagangan RI. 2017. **Peraturan Menteri Perdagangan Republik Indonesia No.27/M-DAG/PER/5/2017 tentang Penetapan Harga Acuan Pembelian Jagung di Tingkat Petani**. Menteri Perdagangan RI. Jakarta

Kementrian Pertanian. 2014. **Varietas Pertiwi 3**. Diakses pada tanggal 09 Februari 2018 melalui <http://www.litbang.pertanian.go.id/varietas/one/696/>

- Kim, Kwang Baek. 2016. ***Image Binarization using Intensity Range of Grayscale Images.*** International Journal of Multimedia and Ubiquitous Engineering 10(7): 1 39-144
- Kippes, Nestor., Juan M.D., Hans A., Vasquez-Gross, Bala A.A., Hikment B., Kenji K. 2016. ***Identification of Gene Vrn-D4 for Enabling Wheat to Adapt to Areas with Warm Winters.*** Okayama University. Okayama
- Klaus, J., Klaus M., Dominique B., and Wolfgang Z. 2011. ***Computers Helping People With Special Needs.*** Springer. Heidelberg
- Kour, Haneet. 2015. ***Analysis on Image Color Model.*** International Journal of Advanced Research in Computer and Communication Engineering 4(12): 233-235
- Kusumadewi, S. 2003. ***Artificial Intelligence ITeknik dan Aplikasinya).*** Graha Ilmu. Yogyakarta
- Liantoni, Febri. 2015. ***Klasifikasi Daun Dengan Perbaikan Fitur Citra Menggunakan Metode K-Nearest Neighbor.*** ULTIMATICS 7(2): 98-104
- Lillesand, T.M., Ralph W. K., Jonathan W.C. 2004. ***Remote Sensing and Image Interpretation (Fifth Edition).*** John Wiley & Sons. Chichester
- Luhulima, Yugo Yudasha, Marji, & Lailil Muflikhah. 2015. ***Sentiment Analysis pada Review Barang Berbahasa Indonesia dengan Metode K-Nearest Neighbor (K-NN).*** Universitas Brawijaya Malang. Malang
- Maillo, J., Sergio R., Isaac T., and Fransisco H. 2017. ***K-NN-IS: An Iterative Spark-Based Design of the K-Nearest Neighbors Classifier for Big Data.*** Knowledge-Based Systems 117: 3-15

- Mansor, M.N. 2012. ***Fuzzy K-NN and K-NN Algotihm for Fast Infant Cues Detection***. *IFMBE Proceedings* Vol. 39, pp.1260-1263
- Munarto, Ri, Endi P., Rensi S. 2014. **Klasifikasi Kualitas Biji Jagung Manis Berdasarkan Fitur Warna Menggunakan Fuzzy Logic**. Simposium Nasional RAPI XIII : 5-12
- Munir, Rinaldi. 2004. **Pengolahan Citra Digital Dengan Pendekatan Algoritmik**. Informatika. Bandung
- Nahari, Anugrah. 2010. **Implementasi Temu Kembali Citra Mammogram dengan Teknik Ekstraksi Fitur Tektur dan Fitur Bentuk**. Internetwork Indonesia Journal 1(1): 1-9
- Nugraheny, Dwi. 2015. **Metode Nilai Jarak Guna Kesamaan Atau Kemiripan Ciri Suatu Citra (Kasus Deteksi Awan Cumulonimbus Menggunakan Principal Component Analysis)**. Jurnal Angkasa 7(2): 21-30
- Phivin, V.A.G dan Subhajini. 2017. **A Flexible Algorithm for Conversion of RGB Image to Gray Image using MATLAB**. International Journal of Control Theory and Aplication 10(27):153-161.
- Praharasty Anggit. 2008. **Simulasi Pendeteksian Garis Lurus (Stright Line) Pada Citra Digital Menggunakan Matlab 7.1**. Skripsi. Universitas Diponegoro. Semarang
- Prahudaya, T. Y. dan Agus H. 2017. **Metode Klasifikasi Mutu Jambu Biji Menggunakan KNN Berdasarkan Fitur Warna Dan Tekstur**. Jurnal Teknosains 2(6): 113-123
- Prasetyo, Eko. 2012. **Pengolahan Citra digital Dan Aplikasinya Menggunakan Matlab**. ANDI. Yogyakarta
- Purnamasari, Intan dn Sutojo. 2016. **Pengenalan Ciri Garis Telapak Tangan Menggunakan Ekstraksi Fitur GLCM**

dan Metode K-NN. Skripsi. Universitas Dian Nuswantoro. Semarang

Purwono dan Hartono R. 2005. **Bertanam Jagung Unggul.** Bogor

Pusdatin. 2016. **Outlook Komoditas Pertanian Tanaman Jagung.** Pusat Data dan Sistem Informais Pertanian Kementrian Pertanian. Jakarta

Putra, Darma. 2010. **Pengolahan Citra Digital.** ANDI. Yogyakarta

Rao, Venkat N. Dan A. Govardhan. 2012. **Analysis And Assessment Of Surface Image Texture Mechanisms.** Journal of Global Research in Computer Science 3(9): 6-12

Respati E., Hasanah L., Wahyuningsih, Sehusman, Manurung M, Supriyati Y, dan Rinawati. 2013. **Buletin Konsumsi Pangan.** Pusat Data dan Sistem Informasi Pertanian 4(2): 1-56

Rukmana, Rahmat. 1997. **Usaha Tani Jagung.** Kanisius. Yogyakarta

Saeed, A., Muhammad T., Ibrahim, Nazir A., dan Abu M.A. 2014. **Identification of Canola Seeds using Nearest Neighbor and K-Nearest Neighbor Algorithms.** Australian Journal of Business Science Design & Literature 7(1): 36-43.

Santi, Rina C.N. 2011. **Teknik Perbaikan Kualitas Citra Satelit Cuaca dengan Sataid.** Jurnal Teknologi Informasi DINAMIK 16(2): 101109

Santos, Augusto S. D. 2015. **Pengenalan Secara Real Time Rambu Larangan pada Lalu Lintas Menggunakan Discrete Consine Transform dan Jarak Canberra.** Skripsi. Universitas Sanata Dharma. Yogyakarta

- Sela, Enny I. Dan Muhammad Ihsan. 2017. **Deteksi Kualitas Telur Menggunakan Analisis Tekstur.** IJCCS 2(11): 199-208
- Semary, N., Mohiy H., Hatem Abdul K. and Alaa Abbas. 2013. **Novel Compression System for Hue-Saturation and Intensity Color Space.** The International Arab Journal of Information Technology 10(6): 546-552
- Sinwar, D. dan Rahul K. 2014. **Study of Euclidean and Manhattan Distance Metrics using Simple K-Means Clustering.** International Journal For Research In Applied Science And Engineering Technology (IJRASET) 2(5): 270-274
- Siqueira, F.R.D., Schwartz W.R., Pedrini H. 2013. **Multiscale gray level co-Occurence Atrices for Texture Description.** Journal Neurocomputing : 336-345
- Somantri, Agus S. dan Miskiyah. 2012. **Sistem Keamanan Pangan Berbahan Baku Jagung.** *Buletin Teknologi Pascapanen Pertanian* 8(2): 112-119
- Somantri, Lili. 2009. **Teknologi Penginderaan Jauh (Remote Sensing).** Universitas Pendidikan Indonesia. Bandung
- Sujito dan Mamud Y. 2016. **Pemutuan Fisik Beras Dengan Teknik Pelabelan Flod Filling dan Pengukuran Parameter RGB Citra Digital.** Jurnal Informatika Merdeka Pasuruan 1(3): 14-38
- Sulistyo, W., Yos Richard B., dan Filipus Frans. 2009. **Analisis Penerapan Metode Median Filter Untuk Mengurangi Noise Pada Citra Digital.** Konferensi Nasional Sistem dan Informatika. Bali
- Sunarya, I Made G., Made Windu A.K., dan Ida Ayu P.P. 2015. **Segmentasi Citra Tulisan Tangan Aksara Bali Berbasis**

Proyeksi Vertikal dan Horisontal. Jurnal Informatika 9(1): 982-992

Suresh, A. 2012. **Image texture Classification using Gray Level Co-Occurrence Matrix Based Statistical Features.** European Journal of Scientific Research 75(4): 591-507

Sutoyo, T., Edy M., Vincent S., dan Oky Dwi N. 2009. **Teori Pengolahan Citra Digital.** Andi. Yogyakarta

Synder, W. 2005. **Active Contour for Multispektral Images with Non-homogeneous Sub-regions.** Dept. of Electrical and Computer Engineering North Carolina State University. Raleigh

Tan, P., Steinbach M., and Kumar V. 2006. **Introduction to Data Mining.** Pearson Education. Boston San Fransisco

Tangendjaja, B., Yusmichad Y. Dan Nyak Ilham. 2005. **Analisis Ekonomi Permintaan Jagung untuk Pakan.** Ekonomi Jagung Indonesia p 229-254

Tobias, D. S. dan Anastasia R. W. 2016. **Deteksi Glaukoma pada Citra Fundus Retina dengan Metode K-Nearest Neighbor.** *Seminar Nasional Ilmu Komputer (SNIK), Semarang, pp.92-99*

Trstenjak, B., Mikac S., Donko D. 2014. **K-NN With TF-IDF Based Framework for Text Categorization.** *Procedia Engineering 69, pp 1356-1364*

Wahyudi, E., Dedi T., dan Ikhwan R. 2015. **Identifikasi Teks Dokumen Menggunakan Metode Profile Projection dan Template Matching.** Jurnal Coding Sistem Komputer Untan 3(2): 1-10

Weinberger, K., Blitzer J., and Saul K. 2006. **Distance Metric Learning for Large Margin Nearest Neighbor**

Classification. *Proceeding of the Advances in Neural Information Processing Systems (NIPS)*, pp 1473–1480

Wen, Che Yen and Chou Chun Ming. 2004. **Color Image Models and its Applications to Document Examination.** Forensic Science Journal. 3(1): 23-32

Windana, F., Moechammad S. Dan Purnomo Budi S. 2014. **Implementasi Kombinasi Feature Extraction untuk Content Based Image Retrieval.** Jurnal EECCIS 8(2): 169-174

Wu, Xindong and Vipin Kumar. 2009. **The Top Ten Algorithms in Data Mining.** CRC Press. Boca Raton

Wurdianarto, S.R., Novianto dan Rosyidah. 2014. **Perbandingan Euclidean Distance dengan Canberra Distance Pada Face Recognition.** Jurnal Teknologi: 31-37

Zhang, S., Debo C., Ming Z. and Lianli G. 2016. **Self Representation Nearest Neighbor Search for Classification.** Journal Neurocomputing 195: 137-142

Zou, Xiaobo and Jiewen Zhou. 2015. **Nondestructive Measurement in Food and Agro-products.** Springer. Beijing

Zubachtirodin dan Firdaus K. 2012. **Varietas Bersari Bebas dalam Usahatani Jagung di Indonesia.** IPTEK Tanaman Pangan 7(1): 25-31