



TESIS - KI142502

**KLASIFIKASI SEL SERVIKS PADA CITRA  
*PAP SMEAR* BERDASARKAN FITUR BENTUK  
DESKRIPTOR REGIONAL DAN FITUR TEKSTUR  
*UNIFORM ROTATED LOCAL BINARY PATTERN***

MOHAMMAD SHOLIK  
5113201039

DOSEN PEMBIMBING  
Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

PROGRAM MAGISTER  
BIDANG KEAHLIAN KOMPUTASI CERDAS DAN VISUALISASI  
JURUSAN TEKNIK INFORMATIKA  
FAKULTAS TEKNOLOGI INFORMASI  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA  
2017





THESIS - KI142502

**CLASSIFICATION OF CERVICAL CELLS IN  
PAP SMEAR IMAGES BASED ON REGIONAL  
DESCRIPTOR SHAPE AND UNIFORM ROTATED  
LOCAL BINARY PATTERN TEXTURE FEATURES**

MOHAMMAD SHOLIK  
5113201039

SUPERVISOR  
Dr. Eng. Chastine Faticah, S.Kom., M.Kom.

MASTER PROGRAM  
THE EXPERTISE OF INTELLIGENT COMPUTING AND VISION  
DEPARTMENT OF INFORMATICS ENGINEERING  
FACULTY OF INFORMATION TECHNOLOGY  
SEPULUH NOPEMBER INSTITUTE OF TECHNOLOGY  
SURABAYA  
2017



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

di

Institut Teknologi Sepuluh Nopember Surabaya

oleh :

Mohammad Sholik

Nrp. 5113201039

Dengan judul :

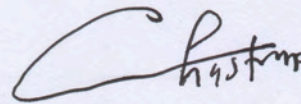
KLASIFIKASI SEL SERVIKS PADA CITRA *PAP SMEAR*  
BERDASARKAN FITUR BENTUK DESKRIPTOR REGIONAL DAN  
FITUR TEKSTUR *UNIFORM ROTATED LOCAL BINARY PATTERN*

Tanggal Ujian : 22-6-2017

Periode Wisuda : 2016 Genap

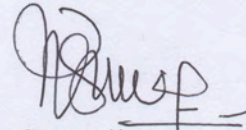
Disetujui oleh :

Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.  
NIP. 197512202001122002



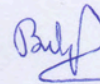
(Pembimbing 1)

Dr. Eng. Nanik Suciati, S.Kom., M.Kom.  
NIP. 197104281994122001



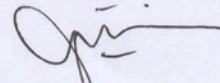
(Penguji 1)

Bilqis Amaliah, S.Kom., M.Kom.  
NIP. 197509172001122002



(Penguji 2)

Dini Adni Navastara, S.Kom., M.Sc.  
NIP. 198510172015042001



(Penguji 3)

Dekan Fakultas Teknologi Informasi,

Dr. Agus Zainal Arifin, S.Kom., M.Kom.  
NIP. 197208091995121001





# **KLASIFIKASI SEL SERVIKS PADA CITRA *PAP SMEAR* BERDASARKAN FITUR BENTUK DESKRIPTOR REGIONAL DAN FITUR TEKSTUR *UNIFORM ROTATED LOCAL BINARY PATTERN***

Nama Mahasiswa : Mohammad Sholik  
NRP : 5113201039  
Pembimbing : Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

## **ABSTRAK**

Kanker serviks merupakan salah satu penyebab utama kematian kanker pada wanita di dunia. Hal ini dapat dicegah jika diperiksa pada tahap *pre-cancerous*. *Papanicolaou test* adalah pemeriksaan kanker serviks secara manual yang membutuhkan waktu lama dalam mengklasifikasi sel, sehingga dibutuhkan sistem klasifikasi sel berbasis komputer.

Perubahan orientasi objek pada saat akuisisi memerlukan metode ekstraksi fitur yang *invariant* terhadap rotasi. Area dan *compactness* merupakan deskriptor regional bentuk yang tidak berpengaruh terhadap orientasi objek dan deskriptor tekstur merupakan deskriptor penting untuk mendeteksi setiap tahapan kanker. Ekstraksi fitur tekstur yang telah digunakan dalam kombinasi fitur sebelumnya untuk klasifikasi sel serviks pada *dataset* Herlev antara lain Homogenitas GLCM, *Uniform Rotation Invariant Local Binary Pattern* (LBP<sup>riu</sup>), dan *Local Binary Pattern Histogram Fourier* (LBP-HF). Namun perhitungan GLCM sensitif terhadap rotasi, LBP<sup>riu</sup> mengabaikan beberapa informasi orientasi lokal dan kehilangan beberapa informasi diskriminatif citra karena pemetaan yang padat, dan transformasi *fourier* LBP-HF mengabaikan penataan struktur histogram dengan hanya mempertimbangkan *magnitude* spektrum transformasi, sehingga kehilangan beberapa informasi diskriminatif dan informasi frekuensi citra. *Uniform Rotated Local Binary Pattern* (uRLBP) merupakan metode ekstraksi fitur yang dapat mengatasi kelemahan metode tekstur sebelumnya dengan mengatur arah referensi lokal mengikuti orientasi objek yang dapat mempertahankan informasi orientasi lokal dan informasi diskriminatif citra sehingga mencapai *invariant* terhadap rotasi. Penelitian sebelumnya menunjukkan peningkatan akurasi ketika fitur bentuk dan fitur tekstur dikombinasikan yang menjadi dasar dalam mengombinasikan fitur bentuk dan fitur tekstur untuk membedakan ciri antar kelas sel agar lebih spesifik.

Penelitian ini mengusulkan kombinasi fitur bentuk deskriptor regional dan fitur tekstur uRLBP yang *invariant* terhadap rotasi untuk mengklasifikasikan sel serviks pada citra *pap smear*. Dari evaluasi diperoleh bahwa kombinasi fitur bentuk dan fitur tekstur untuk klasifikasi berdasarkan dua kategori sel dan tujuh kelas sel untuk klasifikasi sel serviks pada citra *pap smear* menggunakan *Fuzzy k-NN*, yaitu dengan akurasi tertinggi 91.59% dan 67.89% ketika parameter ( $P=8, R=3$ ) pada uRLBP dan  $k=14$  pada *Fuzzy k-NN*.

**Kata Kunci:** klasifikasi, sel serviks, citra *pap smear*, fitur bentuk, fitur tekstur.

**[Halaman ini sengaja dikosongkan]**



# CLASSIFICATION OF CERVICAL CELLS IN PAP SMEAR IMAGES BASED ON REGIONAL DESCRIPTOR SHAPE AND UNIFORM ROTATED LOCAL BINARY PATTERN TEXTURE FEATURES

By : Mohammad Sholik  
Student Identity Number : 5113201039  
Supervisor : Dr. Eng. Chastine Fatichah, S.Kom., M.Kom.

## ABSTRACT

Cervical cancer is one of the leading causes of cancer death in women in the world. This can be prevented if examined at a pre-cancerous stage. Papanicolaou test is a manual cervical cancer examination that takes a long time in classifying the cell, so it takes a computer-based classification system.

Changes in object orientation at the time of acquisition require feature extraction methods that produces a rotation invariant. Area and compactness are regional descriptor shapes that have no effect on object orientation and texture descriptor is an important to detect every stage of cancer. Extraction of texture features that have been used in previous feature combinations for cervical cell classification in Herlev dataset including homogeneity of GLCM, Uniform Rotation Invariant Local Binary Pattern ( $LBP^{riu}$ ), and Local Binary Pattern Histogram Fourier (LBP-HF). But the GLCM calculation is sensitive to rotation,  $LBP^{riu}$  ignores some local orientation information and loses some discriminative information of image due to the compact mapping, and the fourier transform of LBP-HF completely ignores the structure arrangement of histogram by only considering the magnitude of the transformation spectrum, thereby losing some discriminative information and the information present in the frequency from image. Uniform Rotated Local Binary Pattern (uRLBP) is a feature extraction method that able to overcome the limitation of previous texture methods by setting the local reference direction according to object orientation that able to maintain local orientation information and discriminative information so as to achieve rotation invariant. Previous studies have proven that classification accuracy will be increased when the shape and texture features were combine. This become the motivation in combining shape and texture feature to discriminate the between-class characteristics of the cell to be more specific.

This study proposes the combination of regional descriptor shape and uRLBP texture features that produces a rotation invariant feature to classify cervical cells in pap smear images. The evaluation result shows that the combination of shape and texture features is able to produce a rotation invariant feature and used to classify cervical cells in pap smear images based on two cell categories and seven cell classes using Fuzzy  $k$ -NN, with highest accuracy is 91.59% and 67.89% respectively when parameters ( $P=8, R=3$ ) on uRLBP and  $k=14$  on Fuzzy  $k$ -NN.

**Keywords:** *classification, cervical cells, pap smear images, shape features, texture features.*

**[Halaman ini sengaja dikosongkan]**

## KATA PENGANTAR



Alhamdulillah rabbil' alamin, segala puji bagi Allah SWT atas karunia dan kemudahan yang telah diberikan, sehingga buku tesis ini dapat diselesaikan dengan baik. Sholawat serta salam senantiasa tercurahkan kepada Nabi akhir zaman Baginda Sayyidina Muhammad SAW beserta keluarga, sahabat, tabi'in, tabi'ut tabi'in, dan umatnya hingga akhir zaman. Tesis ini dibuat sebagai salah satu syarat dalam menyelesaikan Program Studi Magister di Institut Teknologi Sepuluh Nopember Surabaya. Penulis menyadari bahwa tesis ini dapat diselesaikan karena dukungan dari berbagai pihak, baik dalam bentuk dukungan moral atau material.

Melalui kesempatan ini dengan kerendahan hati, penulis mengucapkan terima kasih dan penghargaan setinggi-tingginya kepada semua orang untuk semua bantuan dan dukungan yang diberikan, antara lain kepada :

1. Ayahanda tercinta H. Mohammad Yasin (alm) dan Ibunda tercinta Salasatun untuk semua do'a, pengorbanan, dan usaha yang tidak mengenal lelah mendidik dan membimbing dengan sepenuh hati serta ketulusan budi untuk keberhasilan penulis.
2. Ibu Dr. Eng. Chastine Fatichah, S.Kom., M.Kom., selaku pembimbing tesis yang senantiasa memberikan arahan dan bimbingan kepada penulis. Semoga Allah SWT senantiasa memberikan keutamaan dan rahmat kepada Ibu dan keluarga.
3. Ibu Dr. Eng. Nanik Suciati, S.Kom., M.Kom., Ibu Bilqis Amaliah, S.Kom., M.Kom., dan Ibu Dini Adni Navastara, S.Kom., M.Sc., selaku dosen penguji yang telah memberikan masukan dan kritik yang membangun untuk tesis ini.
4. Seluruh dosen magister teknik informatika yang telah memberikan ilmu pengetahuan kepada penulis selama menempuh studi pascasarjana.

5. Saudara-saudara penulis Nur Hadi, Sholeh, Muhammad Anshori, Lisaida, dan Mu'iroh, yang telah memberikan dukungan dan semangat dalam menyelesaikan studi pascasarjana.
6. Keponakan tercinta Mohammad Haedar Ali Khafid dan Nihayatus Sailir Rohma, dengannya telah menumbuhkan inspirasi untuk selalu semangat dalam menyongsong masa depan.
7. Teman seperjuangan, Dhika, Imron, Kurniawan, dan teman seangkatan lainnya yang tidak dapat disebutkan satu persatu, terima kasih atas bantuan dan motivasi yang telah diberikan.

Akhirnya dengan segala kerendahan hati penulis menyadari masih banyak terdapat kekurangan pada tesis ini. Oleh karena itu, segala saran dan kritik yang bersifat membangun sangat diperlukan demi kesempurnaan tesis ini. Semoga tesis ini dapat memberikan manfaat bagi ilmu pengetahuan dan dapat memberikan kontribusi dalam pengembangan ilmu pengetahuan dan teknologi yang akan datang.

Surabaya, 20 Juli 2017

Mohammad Sholik

## DAFTAR ISI

<b>JUDUL PENELITIAN .....</b>	<b>I</b>
<b>LEMBAR PENGESAHAN .....</b>	<b>V</b>
<b>ABSTRAK .....</b>	<b>VII</b>
<b>ABSTRACT .....</b>	<b>IX</b>
<b>KATA PENGANTAR.....</b>	<b>XI</b>
<b>DAFTAR ISI.....</b>	<b>XIII</b>
<b>DAFTAR GAMBAR.....</b>	<b>XVII</b>
<b>DAFTAR TABEL .....</b>	<b>XIX</b>
<b>BAB 1 PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	4
1.3 Tujuan Penelitian .....	4
1.4 Manfaat Penelitian .....	5
1.5 Kontribusi Penelitian .....	5
1.6 Batasan Masalah .....	5
<b>BAB 2 KAJIAN PUSTAKA DAN DASAR TEORI.....</b>	<b>7</b>
2.1 Kanker Serviks.....	7
2.2 Anatomi Serviks Uterus .....	8
2.3 <i>Papanicolaou Smear</i> dan <i>Sel Papanicolaou</i> .....	9
2.4 Fitur Citra Sitologi .....	11
2.5 Ekstraksi Fitur .....	11
2.5.1 Ekstraksi Fitur Bentuk Deskriptor Regional.....	11
2.5.1.1 Area ( <i>A</i> ).....	11
2.5.1.2 <i>Compactness (C)</i> .....	12
2.5.1.3 Perimeter ( <i>P</i> ).....	12
2.5.2 Ekstraksi Fitur Tekstur.....	13
2.5.2.1 <i>Rotated Local Binary Pattern (RLBP)</i> .....	13
2.5.2.2 <i>Uniform Rotated Local Binary Pattern (uRLBP)</i> .....	18

2.5.2.3	Perbandingan Metode Variasi <i>Local Binary Pattern</i> .....	18
2.6	<i>Fuzzy k-Nearest Neighbor (Fuzzy k-NN)</i> .....	21
2.7	Normalisasi Data .....	22
2.8	Akurasi Pengukuran Kinerja Klasifikator .....	22
2.9	Metode Evaluasi Klasifikator .....	24
2.9.1	<i>K-Fold Cross Validation</i> .....	24
2.9.2	<i>Holdout</i> .....	24
<b>BAB 3</b>	<b>METODOLOGI PENELITIAN</b> .....	<b>25</b>
3.1	Rancangan Sistem .....	25
3.1.1	<i>Dataset</i> .....	26
3.1.2	Praproses .....	27
3.1.3	Kombinasi Fitur Bentuk Deskriptor Regional dan Fitur Tekstur <i>Uniform Rotated Local Binary Pattern (uRLBP)</i> .....	30
3.1.4	Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	32
3.2	Uji Coba dan Analisis .....	33
<b>BAB 4</b>	<b>HASIL DAN PEMBAHASAN</b> .....	<b>37</b>
4.1	Lingkungan Uji Coba .....	37
4.2	Data Uji Coba .....	37
4.3	Uji Coba .....	39
4.3.1	Uji Coba Fitur Tekstur Citra Acuan untuk Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	40
4.3.2	Uji Coba Fitur Tekstur yang <i>Invariant</i> terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	45
4.3.3	Uji Coba Fitur Bentuk yang <i>Invariant</i> terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	50
4.3.4	Uji Coba Kombinasi Fitur Bentuk dan Fitur Tekstur yang <i>Invariant</i> terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra <i>Pap</i> <i>Smear</i> .....	52
4.3.5	Uji Coba Perbandingan Metode Kombinasi Fitur dengan Metode Kombinasi Fitur Sebelumnya .....	57
4.4	Pembahasan Hasil Uji Coba .....	61

4.4.1	Fitur Tekstur Citra Acuan untuk Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	61
4.4.2	Fitur Tekstur yang <i>Invariant</i> terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	63
4.4.3	Fitur Bentuk yang <i>Invariant</i> terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	67
4.4.4	Kombinasi Fitur Bentuk dan Fitur Tekstur yang <i>Invariant</i> terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra <i>Pap Smear</i> .....	70
4.4.5	Perbandingan dengan Metode Sebelumnya .....	75
<b>BAB 5 KESIMPULAN DAN SARAN .....</b>		<b>81</b>
4.1	Kesimpulan .....	81
5.2	Saran .....	83
<b>DAFTAR PUSTAKA .....</b>		<b>85</b>
<b>LAMPIRAN 1.....</b>		<b>91</b>
<b>LAMPIRAN 2.....</b>		<b>95</b>
<b>LAMPIRAN 3.....</b>		<b>97</b>
<b>LAMPIRAN 4.....</b>		<b>99</b>
<b>LAMPIRAN 5.....</b>		<b>101</b>
<b>LAMPIRAN 6.....</b>		<b>107</b>
<b>BIOGRAFI PENULIS .....</b>		<b>109</b>

**[Halaman ini sengaja dikosongkan]**



## DAFTAR GAMBAR

Gambar 2.1	Gambaran distribusi <i>epithelium</i> pada sel serviks .....	8
Gambar 2.2	Ilustrasi sel <i>squamous epithelium</i> .....	9
Gambar 2.3	Contoh citra sel <i>pap smear normal superficial</i> .....	10
Gambar 2.4	Contoh citra sel <i>pap smear normal superficial</i> tersegmentasi	10
Gambar 2.5	Ilustrasi luas dan perimeter.....	12
Gambar 2.6	Efek perubahan rotasi antara LBP dan RLBP .....	14
Gambar 2.7	Efek rotasi operator RLBP .....	15
Gambar 2.8	Algoritme Prediksi <i>Fuzzy k-Nearest Neighbor</i> .....	22
Gambar 3.1	Rancangan sistem klasifikasi sel serviks pada citra <i>pap smear</i> .....	25
Gambar 3.2	Contoh citra <i>dataset</i> Herlev sel tunggal .....	26
Gambar 3.3	Contoh citra <i>pap smear</i> warna dan tersegmentasi .....	27
Gambar 3.4	Tahapan praproses citra biner nukleus dan citra biner sel.....	28
Gambar 3.5	Tahapan praproses citra <i>grayscale</i> nukleus .....	30
Gambar 3.6	Tahapan ekstraksi fitur bentuk deskriptor regional .....	31
Gambar 3.7	Tahapan ekstraksi fitur tekstur uRLBP .....	32
Gambar 4.1	Contoh citra <i>grayscale</i> nukleus <i>carcinoma in situ</i> yang telah dirotasi .....	37
Gambar 4.2	Contoh citra biner nukleus <i>carcinoma in situ</i> yang telah dirotasi	38
Gambar 4.3	Contoh citra biner sel <i>carcinoma in situ</i> yang telah dirotasi ..	38
Gambar 4.4	Akurasi klasifikasi citra acuan dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) dan uRLBP ( $P=8,R=3$ ) .....	62
Gambar 4.5	Akurasi klasifikasi citra acuan tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) .....	62
Gambar 4.6	Akurasi klasifikasi berdasarkan fitur tekstur .....	64
Gambar 4.7	Akurasi klasifikasi berdasarkan fitur bentuk.....	68
Gambar 4.8	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur. ....	72

Gambar 4.9	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur. ....	74
Gambar 4.10	Perbandingan akurasi metode untuk dua kategori sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur dengan metode sebelumnya .....	76
Gambar 4.11	Perbandingan akurasi metode untuk tujuh kelas sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur dengan metode sebelumnya .....	76
Gambar 4.12	Penurunan akurasi kombinasi fitur dibandingkan akurasi dengan hanya fitur bentuk untuk dua kategori sel.....	77
Gambar 4.13	Penurunan akurasi kombinasi fitur dibandingkan akurasi dengan hanya fitur bentuk untuk tujuh kelas sel .....	78

## DAFTAR TABEL

Tabel 2.1	Contoh perhitungan nilai operator ( $P=8$ ) gambar sebelum diputar.....	17
Tabel 2.2	Contoh perhitungan nilai operator ( $P=8$ ) gambar setelah diputar $90^\circ$ berlawanan arah jarum jam .....	17
Tabel 2.3	Perbandingan akurasi uRLBP dengan variasi LBP .....	20
Tabel 2.4	Contoh matriks konfusi untuk klasifikasi dua kelas.....	23
Tabel 3.1	Distribusi jumlah sel <i>pap smear</i> .....	27
Tabel 3.2	Penggunaan nilai $R$ pada $strel('disk',R)$ dan $P$ pada $bwareaopen(BW,P)$ untuk operasi morfologi citra <i>ground truth</i> .....	29
Tabel 4.1	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) pada citra acuan dengan <i>10-fold cross validation</i> .....	41
Tabel 4.2	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) pada citra acuan dengan <i>10-fold cross validation</i> .....	41
Tabel 4.3	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=3$ ) pada citra acuan dengan <i>10-fold cross validation</i> .....	42
Tabel 4.4	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) pada citra acuan dengan <i>10-fold cross validation</i> .....	43
Tabel 4.5	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) pada citra acuan dengan <i>10-fold cross validation</i> .....	43
Tabel 4.6	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=3$ ) pada citra acuan dengan <i>10-fold cross validation</i> .....	44
Tabel 4.7	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) yang <i>invariant</i> terhadap rotasi.....	46

Tabel 4.8	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) yang <i>invariant</i> terhadap rotasi .....	46
Tabel 4.9	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=3$ ) yang <i>invariant</i> terhadap rotasi .....	47
Tabel 4.10	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) yang <i>invariant</i> terhadap rotasi .....	48
Tabel 4.11	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) yang <i>invariant</i> terhadap rotasi .....	48
Tabel 4.12	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=3$ ) yang <i>invariant</i> terhadap rotasi .....	49
Tabel 4.13	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur bentuk deskriptor regional yang <i>invariant</i> terhadap rotasi .....	51
Tabel 4.14	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur bentuk deskriptor regional yang <i>invariant</i> terhadap rotasi .....	51
Tabel 4.15	Hasil akurasi klasifikasi dua kategori sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=1$ ) pada uRLBP .....	53
Tabel 4.16	Hasil akurasi klasifikasi dua kategori sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=2$ ) pada uRLBP .....	53
Tabel 4.17	Hasil akurasi klasifikasi dua kategori sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=3$ ) pada uRLBP .....	54
Tabel 4.18	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=1$ ) pada uRLBP .....	55
Tabel 4.19	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=2$ ) pada uRLBP .....	55
Tabel 4.20	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=3$ ) pada uRLBP .....	56
Tabel 4.21	Perbandingan kombinasi fitur dengan kombinasi fitur sebelumnya untuk klasifikasi dua kategori sel.....	59
Tabel 4.22	Perbandingan kombinasi fitur dengan kombinasi fitur sebelumnya untuk klasifikasi tujuh kelas sel.....	59
Tabel 4.23	Perbandingan metode dengan metode sebelumnya untuk klasifikasi dua kategori sel.....	59

Tabel 4.24	Perbandingan metode dengan metode sebelumnya untuk klasifikasi tujuh kelas sel.....	60
Tabel 4.25	Nilai fitur tekstur uRLBP ( $P=8,R=3$ ) citra kelas <i>carcinoma in situ</i> pada berbagai rotasi.....	65
Tabel 4.26	Nilai fitur tekstur uRLBP ( $P=8,R=2$ ) citra kelas <i>carcinoma in situ</i> pada berbagai rotasi.....	66
Tabel 4.27	Contoh data uji fitur tekstur uRLBP ( $P=8,R=3$ ) dan hasil nilai keanggotaan dengan klasifikasi <i>Fuzzy k-NN</i> untuk dua kategori sel.....	67
Tabel 4.28	Contoh data uji fitur tekstur uRLBP ( $P=8,R=2$ ) dan hasil nilai keanggotaan dengan klasifikasi <i>Fuzzy k-NN</i> untuk tujuh kelas sel.....	67
Tabel 4.29	Nilai fitur bentuk nukleus citra kelas <i>normal squamous</i> pada berbagai rotasi .....	69
Tabel 4.30	Nilai fitur bentuk sel citra kelas <i>normal squamous</i> pada berbagai rotasi .....	69
Tabel 4.31	Contoh data uji fitur bentuk dan hasil nilai keanggotaan dengan klasifikasi <i>Fuzzy k-NN</i> untuk dua kategori sel.....	70
Tabel 4.32	Contoh data uji fitur bentuk dan hasil nilai keanggotaan dengan klasifikasi <i>Fuzzy k-NN</i> untuk tujuh kelas sel .....	70
Tabel 4.33	Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur .....	72
Tabel 4.34	Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur .....	74
Tabel 4.35	Perbandingan akurasi kombinasi fitur dengan akurasi fitur bentuk untuk dua kategori sel.....	77
Tabel 4.36	Perbandingan akurasi kombinasi fitur dengan akurasi fitur bentuk untuk tujuh kelas sel .....	78
Tabel 4.37	Contoh nilai keanggotaan klasifikasi dua kategori sel kombinasi fitur bentuk dan fitur tekstur uRLBP.....	79
Tabel 4.38	Contoh nilai keanggotaan klasifikasi dua kategori sel kombinasi fitur bentuk dan fitur tekstur Homogenitas GLCM.....	80

**[Halaman ini sengaja dikosongkan]**

# BAB 1

## PENDAHULUAN

### 1.1 Latar Belakang

Kanker serviks merupakan penyebab utama keempat kematian kanker pada wanita di dunia (Jemal, 2011). Hal ini dapat dicegah jika diperiksa pada tahap *pre-cancerous* (Chankong, 2014). Kanker serviks terjadi karena adanya perkembangan sel-sel abnormal secara cepat dan tidak terkendali pada leher rahim (Njoroge, 2006). *Papanicolaou test* adalah langkah pertama dalam pemeriksaan kanker serviks (Njoroge, 2006). Pemeriksaan terdiri dari pengumpulan sampel sel dari daerah tertentu pada serviks. Sampel sel kemudian diamati melalui mikroskop dan didiagnosis oleh ahli sel secara manual (Martin, 2003). Diagnosis dan Klasifikasi secara manual memerlukan waktu yang lama sehingga dibutuhkan proses klasifikasi sel serviks pada citra *pap smear* berbasis komputer.

Klasifikasi citra sel oleh ahli patologis dilakukan dengan mengamati fitur sel seperti warna sel, ukuran nukleus, sitoplasma, dan area sel. Fitur ini direpresentasikan dalam fitur intensitas dan fitur bentuk. Fitur tersebut dapat mengindikasikan jika terdapat ciri abnormal pada sel serviks, karena sel terinfeksi *Human Papilloma Virus* (HPV) yang bisa berkembang menjadi tahap kanker akan menunjukkan perubahan biologis tertentu seperti ukuran nukleus yang membesar dan warna nukleus sel abnormal yang lebih gelap dibandingkan dengan sel normal (Yusoff, 2010). Selain fitur bentuk dan intensitas, fitur tekstur dapat direpresentasikan sebagai ciri sel untuk mengukur pola *chromatin* sel dalam citra *pap smear* (Rodenacker, 2003). Tekstur merupakan salah satu atribut yang paling penting dari beberapa atribut yang dapat dianalisis dalam gambar medis yakni warna, bentuk, dan tekstur (Kashyap, 2016). Lebih lanjut (Kashyap, 2016) menjelaskan bahwa fitur tekstur merupakan fitur penting untuk mendeteksi setiap tahapan kanker. Konsep tekstur dapat dipahami sebagai distribusi spasial antar piksel di area lokal (Haralick, 1979). Adanya perubahan orientasi sel pada saat akuisisi akan mempengaruhi nilai fitur yang dihasilkan (Rodenacker, 2003).

Penentuan fitur melalui observasi pada perbedaan ciri antarkelas secara visual pada *dataset* akan membantu proses klasifikasi sel untuk mendapatkan ciri yang relevan antar kelas. Tidak semua fitur dapat menghasilkan fitur yang sama jika citra sel yang sama mengalami perubahan orientasi sehingga dibutuhkan metode ekstraksi fitur yang *invariant* terhadap rotasi.

*Dataset* Herlev adalah salah satu *dataset* citra *pap smear* satu sel (*single cell*) yang disediakan oleh Rumah Sakit Universitas Herlev, Denmark. Pada *dataset* ini, fitur intensitas dianggap kurang relevan sebagai fitur untuk mendeskripsikan karakteristik kelas untuk *dataset* Herlev karena tidak ada standardisasi pada metode pewarnaan dan zat warna (*dye/pap stain*) citra *pap smear* pada rumah sakit berbeda (Jantzen, 2006).

Chankong (2014) melakukan ekstraksi fitur bentuk sel berdasarkan deskriptor regional dan deskriptor *boundary*. Deskriptor regional seperti area dan *compactness* adalah deskriptor yang tidak berpengaruh pada orientasi objek (Gonzales, 2002; Jahne, 2007). Deskriptor *boundary* seperti *major axis length* sensitif terhadap *noise* sehingga fitur yang dihasilkan tidak *invariant* terhadap rotasi (Zhang, 2004; Patel, 2016). *Major axis* mengalami kendala ketika dilakukan normalisasi rotasi, karena *Major axis* sensitif terhadap *noise* (Patel, 2016). Persamaan aspek rasio (Najafabadi, 2012; Waldchen, 2017) adalah rasio antara *major axis length* dengan *minor axis length*, sehingga aspek rasio juga tidak dapat dijadikan sebagai fitur yang *invariant* terhadap rotasi (Khusna, 2016). Ada beberapa citra dalam satu kelas normal pada *dataset* Herlev yang mempunyai bentuk area yang mirip dengan kelas abnormal sehingga diperlukan fitur lain yang dapat membedakan ciri antar kelas yakni fitur tekstur.

Nanni (2010) melakukan penelitian untuk mengklasifikasi sel serviks pada citra *pap smear* dengan hanya menggunakan fitur tekstur yaitu fitur varian dari *Local Binary Pattern* (LBP). Penelitian tersebut dapat membedakan kelas normal dan abnormal dengan akurasi masih di bawah 80% karena hanya melibatkan satu fitur yaitu fitur tekstur saja. Hal tersebut menjadi dasar dalam mengombinasikan antara fitur bentuk dan fitur tekstur untuk dapat membedakan ciri khusus antar kelas sel *pap smear*. Plissiti (2011) menggunakan fitur bentuk dan fitur tekstur dengan perhitungan statistik histogram *Uniform Rotation Invariant LBP* (LBP<sup>riu</sup>) pada



daerah nukleus yang digabungkan dengan fitur intensitas untuk klasifikasi sel serviks pada citra *pap smear*. LBP<sup>riu</sup> adalah penggabungan antara *Rotation Invariant Local Binary Pattern* (riLBP) dengan *uniform pattern* yang merupakan operator hasil pengembangan LBP yang mampu mendeskripsikan tekstur yang *invariant* terhadap rotasi (Ojala, 2002), akan tetapi riLBP (Ojala, 2002) mengabaikan beberapa informasi orientasi lokal (Mehta, 2016) dan kehilangan beberapa informasi diskriminatif citra karena pemetaan yang padat (*compact mapping*) (Mehta, 2013). Chankong (2014) menggabungkan fitur bentuk dan fitur tekstur dengan menghasilkan peningkatan akurasi klasifikasi. Chankong (2014) melakukan ekstraksi fitur bentuk sebagai ciri utama sel dan menambahkan perhitungan Homogenitas melalui perhitungan *Gray Level Co-Occurrence Matrix* (GLCM), namun perhitungan *Gray Level Co-Occurrence Matrix* sensitif terhadap *noise* (Rao, 2013) dan sensitif terhadap rotasi (Sadhria, 2015; Wang, 2016), sehingga perhitungan Homogenitas GLCM tidak *invariant* terhadap rotasi. Pasrun (2016) menggunakan *Local Binary Pattern Histogram Fourier* (LBP-HF) untuk mengekstraksi fitur tekstur, namun transformasi *fourier* pada LBP-HF mengabaikan penataan struktur histogram sehingga kehilangan beberapa informasi diskriminatif citra (Mehta, 2013) dan hanya mempertimbangkan *magnitude* spektrum transformasi sehingga mengabaikan informasi frekuensi (Mehta, 2016). *Uniform Rotated Local Binary Pattern* (uRLBP) mempunyai akurasi lebih baik dibandingkan dengan varian LBP lain yang diujikan pada objek dengan orientasi berbeda (Mehta, 2013). Mehta (2013) mengajukan *Rotate Local Binary Pattern* untuk mempertahankan informasi orientasi lokal dan beberapa informasi diskriminatif citra, gagasan utamanya adalah untuk mengatur arah referensi lokal di setiap *circular neighbourhood* dan menghitung deskriptor pada setiap orientasi citra. Ketika citra diputar, arah referensi lokal juga mengalami rotasi dengan derajat yang sama. Maka, deskriptor dihitung sehubungan dengan rotasi citra tetap sama. Untuk mendapatkan informasi diskriminatif tambahan dengan memperoleh informasi intrinsik pada citra dan *robust* terhadap rotasi, Mehta (2013) menggabungkan *uniform pattern* pada *Rotated Local Binary Pattern* (RLBP) menjadi *Uniform Rotated Local Binary Pattern* (uRLBP).

Penelitian ini mengusulkan kombinasi fitur area dan *compactness* berdasarkan perhitungan deskriptor regional bentuk dan fitur tekstur berdasarkan perhitungan *Uniform Rotated Local Binary Pattern* (uRLBP) yang *invariant* terhadap rotasi untuk mengklasifikasikan sel serviks pada citra *pap smear*, diharapkan dapat meningkatkan akurasi klasifikasi dan menghasilkan fitur yang dapat merepresentasikan karakteristik dari masing-masing kelas meskipun dalam posisi orientasi citra masukan yang berbeda.

## 1.2 Rumusan Masalah

Rumusan masalah yang diangkat dalam penelitian ini diuraikan sebagai berikut :

1. Mengekstraksi fitur bentuk melalui perhitungan deskriptor regional bentuk yaitu perhitungan fitur area dan fitur *compactness*.
2. Mengekstraksi fitur tekstur menggunakan metode *Uniform Rotated Local Binary Pattern* yang *invariant* terhadap rotasi.
3. Menggabungkan fitur bentuk deskriptor regional area dan *compactness* dengan fitur tekstur *Uniform Rotated Local Binary Pattern* yang *invariant* terhadap rotasi.
4. Melakukan klasifikasi dengan metode *Fuzzy k-Nearest Neighbor* untuk dua kategori sel yaitu normal dan abnormal serta tujuh kelas sel yaitu *normal squamous*, *intermediate squamous*, *columnar*, *mild dysplasia*, *moderate dysplasia*, *severe dysplasia*, dan *carcinoma in situ* pada citra *pap smear* berdasarkan fitur bentuk deskriptor regional dan fitur tekstur yang *invariant* terhadap rotasi.

## 1.3 Tujuan Penelitian

Tujuan penelitian ini adalah melakukan klasifikasi sel serviks pada citra *pap smear* berdasarkan fitur bentuk deskriptor regional dan fitur tekstur yang *invariant* terhadap rotasi.

#### 1.4 Manfaat penelitian

Manfaat penelitian ini adalah memberikan referensi berupa pemilihan kombinasi fitur bentuk deskriptor regional dan fitur tekstur yang *invariant* terhadap rotasi dengan tepat untuk klasifikasi sel serviks pada citra *pap smear* yang dapat digunakan untuk klasifikasi jenis-jenis sel lainnya.

#### 1.5 Kontribusi Penelitian

Kontribusi penelitian ini adalah mengusulkan kombinasi metode ekstraksi fitur bentuk deskriptor regional yang mendeskripsikan bentuk nukleus dan bentuk sel dan fitur tekstur yang mendeskripsikan tekstur nukleus menggunakan *Uniform Rotated Local Binary Pattern* untuk klasifikasi sel serviks pada citra *pap smear*. Kombinasi fitur ini bertujuan untuk menghasilkan representasi fitur yang dapat menjadi ciri tiap kelas sel yang *invariant* terhadap rotasi dan diharapkan meningkatkan akurasi hasil klasifikasi.

#### 1.6 Batasan Masalah

Permasalahan yang dibahas pada penelitian ini memiliki beberapa batasan sebagai berikut :

1. Data yang digunakan untuk pengujian adalah data citra *pap smear* satu sel dari *dataset* Herlev (Martin, 2003).
2. Citra *pap smear* diklasifikasikan ke dalam dua kategori sel yaitu normal dan abnormal. Kategori normal terdiri dari tiga kelas yaitu *normal squamous*, *intermediate squamous*, dan *columnar* sedangkan kategori abnormal terdiri dari empat kelas yaitu *mild dysplasia*, *moderate dysplasia*, *severe dysplasia*, dan *carcinoma in situ*.
3. Data yang digunakan merupakan citra yang sudah tersegmentasi.
4. Implementasi menggunakan perangkat Lunak Matlab R2013a.

**[Halaman ini sengaja dikosongkan]**

## **BAB 2**

### **KAJIAN PUSTAKA DAN DASAR TEORI**


Bab ini berisi pembahasan kajian pustaka yang menjadi teori pendukung dan acuan dalam penelitian. Pembahasan tersebut meliputi kanker serviks, anatomi serviks uterus, *papanicolaou smear* dan sel *papanicolaou*, fitur citra sitologi dan metode-metode yang digunakan dalam tahapan ekstraksi yakni ekstraksi fitur bentuk berdasarkan parameter deskriptor regional area dan *compactness*, ekstraksi fitur tekstur dengan metode *Uniform Rotated Local Binary Pattern*, perbandingan metode variasi *Local Binary Pattern*, dan tahapan klasifikasi dengan metode *Fuzzy k-Nearest Neighbor*.

#### **2.1 Kanker Serviks**

Kanker serviks adalah pertumbuhan sel-sel yang abnormal secara cepat dan tidak terkendali pada leher rahim (Njoroge, 2006). Studi ilmiah (Greenblatt, 2005) menunjukkan bahwa sel yang terinfeksi virus HPV (*Human Papillomavirus*) sebagai prasyarat dan faktor resiko utama pada perkembangan kanker serviks. *Human Papillomavirus* merupakan patogen menular seksual yang sangat umum (Hallinan, 1999). Kanker serviks bermula pada sel-sel yang melapisi serviks (bagian bawah rahim) (Bora, 2016). Sel-sel normal dari leher rahim secara bertahap berkembang menjadi *pre-cancerous* yang kemudian berkembang menjadi kanker (Bora, 2016). Kanker serviks merupakan penyebab utama keempat kematian kanker pada wanita di dunia (Jemal, 2011). Hal ini dapat dicegah jika diperiksa pada tahap *pre-cancerous* (Chankong, 2014). *Papanicolaou test (pap test)* merupakan teknik pemeriksaan fisik kanker serviks untuk menemukan sel yang berpotensi menjadi tahap kanker dan terindikasi kanker serviks (Chankong, 2014). *Pap test* digunakan untuk mengidentifikasi sel abnormal untuk mengklasifikasikan sel normal dan abnormal (Plissiti, 2011). Sekitar 90% kasus kanker serviks adalah sel *squamous carcinoma* yang timbul dari *metaplastic* (matang) *squamous epithelium* dari zona transformasi (WHO, 2006). Sisanya 10% adalah *adenocarcinoma* timbul dari *columnar epithelium* (Malm, 2013).

## 2.2 Anatomi Serviks Uterus

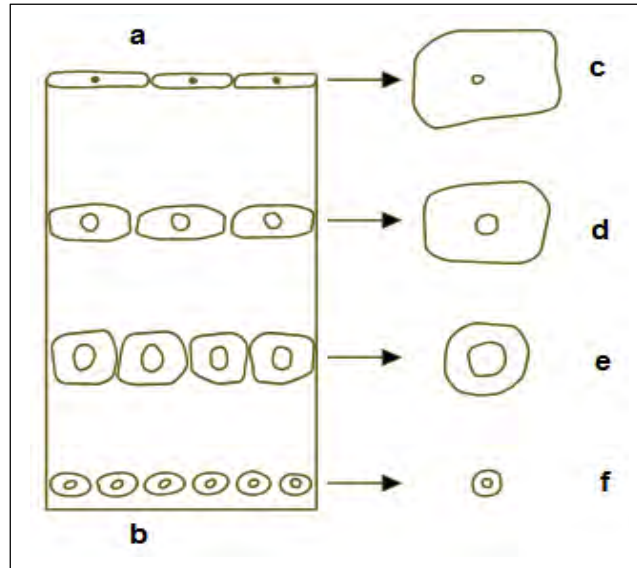
Uterus adalah organ berinding tebal berbentuk buah pir yang terbuat dari otot halus. Serviks (leher rahim) memenuhi sepertiga bagian bawah rahim dan terdiri dari jaringan padat, jaringan *fibromuscular*. Serviks dilapisi dengan epitel, yakni jenis jaringan yang terdiri dari sel-sel padat yang melapisi semua rongga dan permukaan bebas tubuh. Bagian bawah serviks (disebut sebagai leher rahim bagian luar atau *ectocervix*) terletak di dalam vagina dan tertutupi oleh *squamous epithelium*. Bagian atas serviks (leher rahim bagian dalam atau *endocervix*) tertutupi oleh *columnar epithelium*. Daerah persimpangan bertemunya kedua jenis *epithelium*, disebut dengan zona transformasi atau persimpangan *squamocolumnar*. Gambar 2.1 mengilustrasikan daerah leher rahim (Malm, 2013).



Gambar 2.1 Gambaran distribusi *epithelium* pada sel serviks (Hallinan, 1999).

*Squamous epithelium*, memiliki struktur berlapis-lapis yang dapat dikelompokkan ke dalam empat kelompok utama jenis sel antara lain lapisan *basal*, lapisan *parabasal*, lapisan *intermediate*, dan lapisan *superficial* (Gambar 2.1). *Squamous epithelium* terletak pada membran *basal*, yang memisahkan *squamous epithelium* dari *stroma fibromuscular* yang mendasari. Lapisan *basal* melekat pada membran *basal* dan terdiri dari sel-sel bulat. Se-sel yang tersusun mendatar, dengan sitoplasma yang lebih besar saat matang menuju permukaan *epithelium*. Sel-sel di lapisan terluar terus terkelupas (*exfoliated*) dan digantikan dengan sel-sel baru pada saat matang. *Columnar epithelium* terdiri dari lapisan tunggal *tall-cell* yang berada

langsung pada membran *basal* dan jauh lebih tipis dari *squamous epithelium* (Malm, 2013).



Gambar 2.2 Ilustrasi sel *squamous epithelium* (Mehnert, 2003).

Gambar 2.2; (a) permukaan; (b) membran *basal*; (c) sel *superficial* (ukuran diameter nukleus berkisar kurang lebih 5  $\mu\text{m}$ ); (d) sel *intermediate* (ukuran diameter nukleus biasanya 8  $\mu\text{m}$ ); (e) sel *parabasal* (ukuran diameter nukleus biasanya lebih besar dari 8  $\mu\text{m}$ ); (f) sel-sel *basal*

### 2.3 *Papanicolaou Smear* dan Sel *Papanicolaou*


*Papanicolaou smear* adalah metode dalam prosedur medis untuk mendeteksi sel *pre-cancerous* pada *uterine cervix* (serviks uterus)(Norup, 2005) atau metode *screening* untuk mendeteksi potensi *pre-cancerous* dan proses kanker pada serviks (Bora, 2017). Kanker serviks biasanya dapat diobati secara efektif jika terdeteksi pada tahap awal (Labeit, 2013).

Spesimen sitologi dari serviks uterus dikumpulkan dengan *cyto-brush* khusus dan dioleskan pada *glas slide*. Kemudian *slide* diwarnai dengan metode *Papanicolaou*. Sehingga perbedaan komponen sel ditekankan dengan warna spesifik. *Glas slide* tersebut kemudian dilihat dengan mikroskop, sehingga *cyto-technicians* (ahli sel) dapat mendiagnosis sel pada *glas slide*. Ahli sel menggunakan

fitur yang berbeda untuk mendapatkan diagnosis sel seperti ukuran, warna, bentuk, tekstur nukleus, dan sitoplasma. Kepadatan sel di daerah tertentu, dapat mempengaruhi hasil diagnosis. Dibutuhkan ahli sel yang terampil untuk dapat membedakan jenis-jenis sel. Setiap *glas slide*, dapat berisi sampai dengan 300.000 sel. Sehingga diperlukan waktu lama untuk mengamati *slide*. Idealnya spesimen atau bagian sel yang diambil dari beberapa daerah leher rahim tergantung area, *cyto-brush*, *cotton stick*, atau *wooden stick* yang digunakan. Daerah yang paling sering adalah daerah yang mengandung sel-sel dari *columnar epithelium* dan *squamous epithelium* di bagian bawah. Di antara kedua daerah, *metaplastic epithelium* ditemukan, yang disebut dengan zona transformasi (Martin, 2003). Zona transformasi serviks telah diidentifikasi sebagai yang sangat penting sehubungan dengan terjadinya *carcinoma* (Mehnert, 2003;WHO, 2006).



Gambar 2.3 Contoh citra sel *pap smear normal superficial*, (a) daerah nukleus dan (b) daerah sitoplasma (Martin, 2003).



Gambar 2.4 Contoh citra sel *pap smear normal superficial* tersegmentasi, (a) daerah nukleus dan (b) daerah sitoplasma (Martin, 2003).



## 2.4 Fitur Citra Sitologi

Bora (2017) mengajukan klasifikasi fitur citra sel berdasarkan tiga kategori yaitu bentuk, tekstur, dan warna untuk mengklasifikasikan *cervical dysplasia* ke dalam dua kategori kelas (normal dan abnormal). Rodenacker (2003) mengajukan klasifikasi fitur dari citra sel berdasarkan empat kategori utama yaitu *morphometric*, *densitometric*, tekstur, dan struktural. *Morphometric* adalah fitur pengaturan spasial seperti ukuran dan bentuk, *densitometric* adalah fitur yang mengekspresikan nilai *grayscale* secara keseluruhan tanpa mempertimbangkan distribusi spasial yang diekspresikan dengan intensitas total, tekstur atau fitur struktural adalah fitur kombinasi dari beberapa aspek distribusi spasial nilai *grayscale*.

## 2.5 Ekstraksi Fitur

Malm (2013) mendefinisikan fitur adalah deskriptor objek, yang memberikan informasi tentang karakteristik khusus yang diperoleh dari segmentasi citra. Kadir (2013) mendefinisikan deskriptor adalah seperangkat parameter yang mewakili karakteristik tertentu pada objek, yang dapat digunakan untuk menyatakan fitur objek sedangkan fitur dinyatakan dengan susunan bilangan yang dapat dipakai untuk mengidentifikasi objek. Purnomo (2010) mendefinisikan ekstraksi fitur merupakan tahapan untuk memunculkan ciri dan mereduksi dimensi citra dari dimensi tinggi ke dimensi yang lebih rendah.

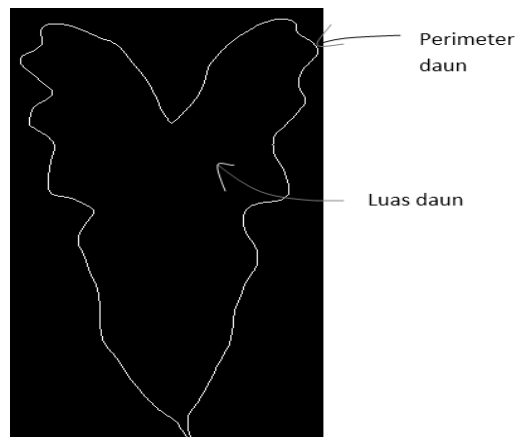
### 2.5.1 Ekstraksi Fitur Bentuk Deskriptor Regional

#### 2.5.1.1 Area (A)

Pada citra biner, area didefinisikan sebagai jumlah piksel yang berada di dalam *region* (Chankong, 2014; Waldchen, 2017; Bora, 2017). Area juga didefinisikan sebagai *zero-order moment* dari objek biner (Jahne, 1997). Kadir (2013) mendefinisikan area sebagai luas suatu objek. Ukuran area dalam perhitungan piksel pada setiap objek adalah kriteria yang baik dalam mengidentifikasi kelainan sel pada citra sitologi (Mahanta, 2012). Gambar 2.5 menunjukkan ilustrasi area dan Persamaan 2.1 menunjukkan area objek (Chankong, 2014).

$$A = \text{Jumlah pixel dari suatu obyek} \quad (2.1)$$

Untuk mendapatkan fitur area digunakan fungsi matlab  $regionprops(x,'y')$  dengan  $x$  adalah citra masukan dan  $y$  adalah properti area.



Gambar 2.5 Ilustrasi luas dan perimeter (Kadir, 2013)

### 2.5.1.2 Compactness ( $C$ )

*Compactness* didefinisikan oleh (Shen, 1994) merupakan fitur bentuk tidak berdimensi yang mengukur kekompakan suatu objek. Persamaan 2.2 menunjukkan perhitungan *compactness* (Shen, 1994; Chankong, 2014).

$$C = \frac{P^2}{A} \quad (2.2)$$

*Compactness* adalah perbandingan dari kuadrat perimeter ( $P^2$ ) dengan area ( $A$ ).

Area, perimeter, dan *compactness* merupakan parameter bentuk yang tidak tergantung pada orientasi objek pada bidang gambar. Dengan demikian ketiga parameter tersebut membedakan objek secara independen (Jahne, 1997).

### 2.5.1.3 Perimeter ( $P$ )

Perimeter atau keliling menyatakan panjang tepi suatu objek (Kadir, 2013) atau banyaknya *point* pembatas objek (Plissiti, 2011). Perimeter merepresentasikan

banyaknya piksel yang mewakili batas objek (Bora, 2017). Untuk mendapatkan perimeter digunakan fungsi matlab *regionprops* ( $x, 'b'$ ) dengan  $x$  adalah citra masukan dan  $b$  adalah properti perimeter. Gambar 2.5 menunjukkan perimeter objek pada suatu citra.

## 2.5.2 Ekstraksi Fitur Tekstur

Tekstur dapat didefinisikan sebagai distribusi spasial antar piksel di area lokal yang ditentukan (Haralick, 1979). Tekstur merupakan fitur penting untuk mendeteksi tahapan kanker karena keunikannya (Kashyap, 2016). Lebih lanjut, Kashyap (2016) menjelaskan bahwa fitur tekstur dapat digunakan untuk mengidentifikasi dan mengklasifikasi tahapan sel kanker. Fitur tekstur juga dapat direpresentasikan sebagai ciri sel untuk mengukur pola *chromatin* sel dalam citra *pap smear* (Rodenacker, 2003).

### 2.5.2.1 Rotated Local Binary Pattern (RLBP)

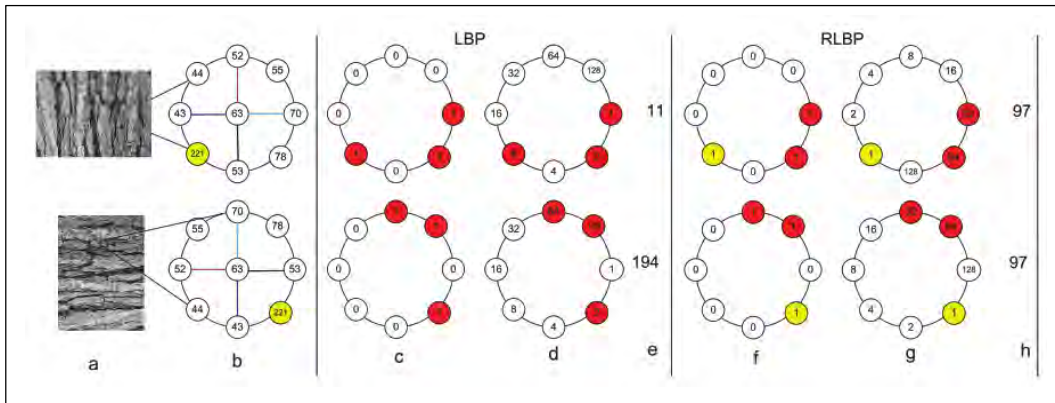
*Local Binary Pattern* (LBP) beroperasi pada area melingkar lokal (*local region*) dengan mengambil perbedaan antara piksel pusat (*central pixel*) dengan piksel ketetanggaan (*neighbor pixel*), didefinisikan sebagai berikut :

$$LBP_{R,P} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot s^p, \quad s(g_p - g_c) = \begin{cases} 1 & g_p \geq g_c \\ 0 & g_p < g_c \end{cases} \quad (2.3)$$

Dimana  $g_c$  dan  $g_p$  adalah nilai *grayscale* piksel pusat dan piksel ketetanggaan.  $p$  adalah indeks ketetanggaan,  $R$  adalah radius dari ketetanggaan melingkar dan  $P$  adalah jumlah ketetanggaan. Koordinat piksel pusat adalah  $(x, y)$  dan koordinat ruang *uniform* ketetanggaan melingkar didefinisikan sebagai berikut  $(x + R \cos(2\pi p/P), y - R \sin(2\pi p/P))$  untuk  $p=0,1,2,\dots,P-1$ . *Uniform* LBP (uLBP), perpanjangan LBP, hanya mempertimbangkan pola halus (*smooth pattern*) yang menjelaskan secara mayoritas (90%) dari total pola biner. Pola biner lokal disebut *uniform* jika kode biner mengandung paling banyak dua transisi dari 0 ke 1 atau sebaliknya (Mehta, 2013). Misalnya, pola 00011110, 01110000 adalah *uniform*

karena kedua pola tersebut terdiri dari 2 transisi, sedangkan 00100010 dan 01110010 adalah tidak *uniform* karena mengandung 4 transisi.

Operator LBP mengambil perbedaan informasi antara piksel pusat dengan piksel ketetanggaannya kemudian menggabungkan perbedaan *sign* ini menggunakan bobot yang unik. Urutan bobot adalah tetap di lingkungan melingkar, yaitu bobot yang sesuai dengan  $g_0$  selalu 1, untuk  $g_1$  adalah 2, dan seterusnya. Jika citra mengalami rotasi, susunan piksel sekitar pusat mengalami pergeseran. Urutan bobot adalah tetap, nilai operator LBP tidak mampu menghadapi perubahan rotasi. Rotasi sederhana pada citra, operator LBP memberikan nilai yang sangat berbeda (Mehta, 2013). Gambar 2.6 menunjukkan rotasi antara LBP dan RLBP.



Gambar 2.6 Efek perubahan rotasi antara LBP dan RLBP (Mehta, 2016).


Gambar 2.6; (a) citra bagian atas merupakan citra sebelum diputar dan citra bagian bawah adalah citra setelah diputar 90° berlawanan arah jarum jam; (b) citra dirotasi berlawanan arah jarum jam mengakibatkan piksel ketetanggaannya juga berotasi dengan sudut 90°; (c) *thresholding* piksel ketetanggaannya, nilai di atas nilai *threshold* ditunjukkan dengan warna merah; (d) bobot berhubungan dengan ketetanggaannya yang mengalami *threshold*; (e) nilai LBP; (f) ketetanggaannya acuan yang mengalami *threshold* ditunjukkan dengan warna kuning; (g) bobot dari ketetanggaannya yang mengalami *threshold*; (h) nilai RLBP antara citra asli dan setelah dirotasi adalah sama.

LBP hanya memperhitungkan perbedaan *sign* akhir deskriptor. Mengabaikan informasi diskriminatif *magnitude*. *Magnitude* menyediakan

informasi telah dimanfaatkan (Guo, 2010) untuk meningkatkan daya diskriminatif operator. Terutama di *neighbourhood* dengan tepi kuat dengan perbedaan *magnitude* dapat memberikan informasi penting. Dengan memanfaatkan perbedaan *magnitude* untuk menemukan arah dominan pada *neighbourhood*. Arah dominan didefinisikan sebagai indeks di kawasan *neighbourhood* yang perbedaannya adalah maksimum. Ketika citra mengalami rotasi, arah dominan di *neighbourhood* juga mengalami rotasi dengan sudut yang sama. Sehingga arah dominan ditetapkan sebagai referensi dan bobot *neighbourhood* (Mehta, 2013).

Untuk mencapai LBP *invariant* terhadap rotasi dengan menggeser bobot secara melingkar sesuai dengan arah dominan. Arah dominan ( $D$ ) di *neighbourhood* adalah indeks ketetanggaan yang perbedaan antara piksel pusat dan piksel ketetanggaan maksimum, didefinisikan oleh (Mehta, 2013) sebagai berikut :

$$D = \arg \max_{p \in (0,1 \dots P-1)} |g_p - g_c| \quad (2.4)$$



Gambar 2.7 Efek rotasi operator RLBP (Mehta, 2013)

Gambar 2.7; (a) citra bagian atas sebelum dirotasi dan citra bagian bawah telah dirotasi dengan arah  $90^\circ$  berlawanan jarum jam; (b) Warna kuning

menunjukkan arah dominan (*dominant direction*) yang menunjukkan selisih piksel dengan piksel pusat bernilai maksimum dibandingkan dengan nilai selisih piksel ketetanggaan lainnya dengan piksel pusat; (c) Nilai hasil *thresholding* ditunjukkan dengan warna merah; (d) Bobot setelah digeser secara melingkar mengikuti arah dominan; (e) Nilai RLBP.

Rotasi pada *neighbourhood* menyebabkan pusatnya bergeser mengikuti arah  $D$  dengan sudut yang sama (Mehta, 2013). Sebagai contoh, dengan mempertimbangkan *neighbourhood* [23 25 28; 167 35 31; 56 67 72], setelah dilakukan *thresholding* kode biner menjadi [01111000], indeks  $D$  adalah 4 (ditampilkan dalam huruf tebal) yang sesuai dengan nilai piksel 167 (Mehta, 2013). Jika citra diputar  $45^\circ$  berlawanan arah jarum jam maka *neighbourhood* juga berputar dengan sudut yang sama dan kode biner bergeser menjadi [00111100] (Mehta, 2013). Indeks  $D$  masih sesuai dengan nilai yang sama yakni (167) tetapi bergeser satu langkah ke sebelah kanan. Pengaturan piksel melingkar di *neighbourhood* tetap sama mengikuti arah  $D$ . Oleh karena itu bobot terendah berada pada posisi indeks  $D$  dan kemudian bobot meningkat sesuai indeks ketetanggaan  $p$ .

Karena arah dominan sebagai acuan pada *neighbourhood* melingkar, maka bobot ditentukan sehubungan dengan itu. Sehingga operator RLBP didefinisikan sebagai berikut (Mehta, 2013) :

$$RLBP_{R,P} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^{mod(p-D,P)} \quad (2.5)$$

Dengan *mod* adalah operasi modulus. Bobot pada definisi rumus diatas adalah  $2^{mod(p-D,P)}$  tergantung pada  $D$ . Indeks *neighbourhood* melingkar  $p$  dan jumlah ketetanggaan  $P$ .

Hasil pergeseran rotasi *invariant*, maka bobot akan mengikuti piksel *neighbourhood*. Gambar 2.7 menunjukkan efek dari rotasi pada fitur RLBP. Warna merah menunjukkan piksel ketetanggaan di atas nilai *threshold*, warna kuning menunjukkan piksel yang sesuai dengan arah dominan  $D$ . Nilai *bit* indeks  $D$  dengan bobot terendah 1 dan bobot lainnya bergeser secara melingkar sesuai dengan perhitungan bobot yang sudah didefinisikan sebelumnya. Pada Gambar 2.7 (d)

dapat dilihat bahwa bobot sesuai dengan posisi dominan adalah sama untuk citra asli dan diputar, meskipun piksel di lokasi yang berbeda. Dengan demikian nilai-nilai RLBP pada dua *neighbourhood* diputar secara berbeda mempunyai nilai sama, sehingga didapatkan nilai yang *invariant* terhadap rotasi. Tabel 2.1 dan tabel 2.2 menunjukkan contoh perhitungan RLBP sesuai dengan gambar 2.7.

Tabel 2.1 Contoh perhitungan nilai operator RLBP ( $P=8$ ) gambar sebelum diputar.

$g_p$	$g_c$	$s(g_p - g_c)$	$ g_p - g_c $	$p$	$D$	$B_p$	$s(g_p - g_c) \cdot B_p$
202	127	1	75	0	3	32	32
170		1	43	1		64	64
53		0	74	2		128	0
221		1	<b>94</b>	3		1	1
43		0	84	4		2	0
44		0	83	5		4	0
52		0	75	6		8	0
56		0	71	7		16	0
Nilai operator $RLBP_{R,P} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot B_p$							97

Tabel 2.2 Contoh perhitungan nilai operator RLBP ( $P=8$ ) gambar setelah diputar  $90^\circ$  berlawanan arah jarum jam.

$g_p$	$g_c$	$s(g_p - g_c)$	$ g_p - g_c $	$p$	$D$	$B_p$	$s(g_p - g_c) \cdot B_p$
53	127	0	74	0	1	128	0
221		1	<b>94</b>	1		1	1
43		0	84	2		2	0
44		0	83	3		4	0
52		0	75	4		8	0
56		0	71	5		16	0
202		1	75	6		32	32
170		1	43	7		64	64
Nilai operator $RLBP_{R,P} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot B_p$							97

Tabel 2.1 dan tabel 2.2 menunjukkan perhitungan operator RLBP pada gambar sebelum diputar dan gambar setelah diputar. Nilai  $B_p$  merupakan bobot ketetanggaan melingkar dan nilai  $D$  merupakan indeks arah dominan. Nilai  $B_p$  didapat dari perhitungan  $2^{\text{mod}(p-D,P)}$ . Sebagai contoh perhitungan bobot  $B_p$  pada tabel 2.1, nilai *grayscale*  $g_0$  adalah 221 menunjukkan selisih maksimum dari  $|g_p -$

$g_c$  | dengan nilai 94 yang disebut *dominant direction* dengan nilai indeks  $D=3$  berada pada indeks  $p=3$ , maka nilai bobot  $B_3=2^{\text{mod}(3-3,8)}=1$ .

Nilai hasil  $s(g_p - g_c)$  didapatkan dengan melakukan *threshold* pada piksel ketetanggaannya dengan piksel pusatnya. Jika  $g_p \geq g_c$ , maka nilai  $s(g_p - g_c)$  adalah 1. Jika  $g_p < g_c$ , maka nilai  $s(g_p - g_c)$  adalah 0. Untuk mendapatkan nilai RLBP diperoleh dengan pendekatan  $RLBP_{R,P} = ((s(g_0 - g_c) \times B_0) + (s(g_1 - g_c) \times B_1) + (s(g_2 - g_c) \times B_2) + \dots + (s(g_{P-1} - g_c) \times B_p))$ ,  $p=0, 1, 2, \dots, P-1$ , atau  $RLBP_{R,P} = \sum_{p=0}^{P-1} (s(g_p - g_c) \cdot B_p)$ , mengacu pada tabel 2.1 dan tabel 2.2.

### 2.5.2.2 Uniform Rotated Local Binary Pattern (uRLBP)

Memfaatkan struktur intrinsik dari pola biner, pola *uniform* diterapkan pada LBP. *Uniform* LBP (uLBP) mencapai kinerja yang lebih baik dibandingkan dengan LBP karena sifat statistik dari pola ini (Mehta, 2013). Akumulasi sejumlah besar pola *uniform* dalam jumlah yang relatif kecil dari histogram *bin* memberikan informasi diskriminatif, yang dimanfaatkan oleh uLBP (Mehta, 2013). Dengan demikian, jika distribusi pola yang diperoleh oleh operator dijaga, keseragaman pola dapat dimanfaatkan untuk meningkatkan daya diskriminatif (Mehta, 2013).

Operator RLBP menghitung pola biner berdasarkan *neighbourhood* piksel seperti halnya operator LBP. Nilai akhir kedua operator tersebut berbeda karena bobot operator RLBP bergeser melingkar sedangkan bobot LBP tetap. Karena pola biner sama untuk kedua operator pada distribusi pola *uniform* yang digunakan untuk menangkap informasi diskriminatif, Mehta (2013) menerapkan pola *uniform* pada operator RLBP. Operator *uniform* RLBP diberikan sebagai  $U (RLBP_{R,P})$ , dengan  $U()$  adalah tabel yang mendefinisikan pemetaan dari pola biner ke pola *uniform*. Untuk *neighbourhood* piksel  $P$ , tabel lookup  $U()$  terdiri dari  $2^P$  dan nilai-nilai *output* pola *uniform*  $P (P-1) + 3$  (Mehta, 2013).

### 2.5.2.3 Perbandingan Metode Variasi Local Binary Pattern

*Local Binary Pattern* (LBP) menghasilkan banyak varian penelitian untuk mengekstraksi tekstur objek suatu citra. Karakteristik tekstur citra dan orientasi objek yang berbeda pada saat akuisisi menjadi bidang penelitian yang menarik



untuk mendapatkan ciri spesifik suatu objek. LBP standar mengalami kendala ketika suatu objek dirotasi sehingga diperlukan deskriptor fitur tekstur yang *invariant* terhadap rotasi. Ojala (2002), mengenalkan *Rotation Invariant Local Binary Pattern* (riLBP) dan *Uniform Rotation Invariant Local Binary Pattern* ( $LBP^{riu}$ ), untuk mengatasi kelemahan LBP ketika objek diputar beberapa arah dengan membuat representasi tetap melalui transformasi setiap deskriptor lokal yang *invariant* terhadap rotasi dan mendeskripsikan keseluruhan gambar.

Ahonen (2009) menjelaskan bahwa  $LBP^{riu}$  dengan perhitungan transformasi deskriptor lokal yang *invariant* terhadap rotasi kemudian mendeskripsikan keseluruhan gambar dari hasil deskriptor lokal sehingga metode ini dapat menghilangkan distribusi pola relatif. Ahonen (2009) dalam mempertahankan informasi distribusi relatif dari pola *uniform* LBP mengajukan *Local Binary Pattern Histogram Fourier* (LBP-HF) untuk mengatasi kelemahan dari  $LBP^{riu}$ . LBP-HF menghitung histogram yang merepresentasikan keseluruhan region dan perhitungan *invariant* tidak harus diimplementasikan pada setiap lokasi piksel (Pasrun, 2016).

$LBP^{riu}$  yang merupakan penggabungan antara *uniform pattern* dan riLBP, akan tetapi riLBP mengabaikan beberapa informasi orientasi lokal (Mehta, 2016). Mehta (2013) juga menjelaskan bahwa riLBP kehilangan beberapa informasi diskriminatif citra karena pemetaan yang padat (*compact mapping*). Transformasi *fourier* pada LBP-HF mengabaikan penataan struktur histogram sehingga kehilangan beberapa informasi diskriminatif citra (Mehta, 2013) lebih lanjut (Mehta, 2016) menjelaskan bahwa LBP-HF hanya mempertimbangkan *magnitude* spektrum transformasi *fourier* dengan mengabaikan informasi frekuensi. Mehta (2013) mengajukan *Rotated Local Binary Pattern* (RLBP) untuk mengatasi kelemahan dari  $LBP^{riu}$  dan LBP-HF dengan mempertahankan informasi orientasi lokal dan beberapa informasi diskriminatif citra, gagasan utamanya adalah untuk mengatur arah referensi lokal di setiap *circular neighbourhood* dan menghitung deskriptor pada setiap orientasi citra. Ketika citra diputar, arah referensi lokal juga mengalami rotasi dengan derajat yang sama. Maka, deskriptor dihitung sehubungan dengan rotasi citra tetap sama. Untuk mendapatkan informasi diskriminatif tambahan dengan memperoleh informasi intrinsik pada citra dan *robust* terhadap

rotasi, Mehta (2013) menggabungkan *uniform pattern* pada RLBP menjadi *Uniform Rotated Local Binary Pattern* (uRLBP). Mehta (2013) mengujikan uRLBP pada *dataset* objek yang telah dirotasi beberapa arah yaitu *dataset outex-10* dan *dataset outex-12*, dengan mengklasifikasikan objek ke dalam kelas tekstur dari masing-masing *dataset*. Hasil pengujian dibandingkan dengan variasi LBP lainnya, uRLBP menunjukkan akurasi terbaik untuk dua *dataset* tersebut. Tabel 2.3 menunjukkan perbandingan akurasi uRLBP dengan variasi LBP.

Tabel 2.3 Perbandingan akurasi uRLBP dengan variasi LBP (Mehta, 2013).

Metode	Dataset Outex-10		Dataset Outex-12	
	Akurasi	Jumlah Fitur	Akurasi	Jumlah Fitur
LBP	52.66	256	54.8	256
uLBP	54.19	59	54.54	59
riLBP	83.15	36	66.40	36
LBPrui	84.01	10	62.23	10
LBP-HF ( $P=8,R=1$ )	78.46	38	75.48	38
LBP-HF ( $P=8,R=2$ )	83.46	38	80.30	38
LBP-HF ( $P=8,R=3$ )	87.81	38	82.97	38
RLBP ( $P=8,R=1$ )	86.41	256	72.35	256
RLBP ( $P=8,R=2$ )	89.82	256	80.88	256
RLBP ( $P=8,R=3$ )	90.39	256	85.68	256
uRLBP ( $P=8,R=1$ )	88.07	59	74.86	59
uRLBP ( $P=8,R=2$ )	92.94	59	83.19	59
uRLBP ( $P=8,R=3$ )	<b>95.96</b>	<b>59</b>	<b>88.01</b>	<b>59</b>

Tabel 2.3 menunjukkan uji coba (Mehta, 2013), uRLBP menghasilkan akurasi terbaik pada parameter ( $P=8,R=3$ ) dengan akurasi 95.96% untuk *dataset outex-10* yang terdiri dari 4320 citra 24 kelas tekstur setiap kelas tekstur terdiri dari 20 citra dan setiap citra dirotasi 9 arah ( $0^\circ, 5^\circ, 10^\circ, 15^\circ, 30^\circ, 45^\circ, 60^\circ, 75^\circ, 90^\circ$ ) dengan pencahayaan tetap. Untuk 20 citra pada setiap kelas tekstur yang bernilai rotasi  $0^\circ$  digunakan sebagai data latih dengan jumlah citra  $20 \times 24 = 480$  citra. Sedangkan citra yang dirotasi 8 arah ( $5^\circ, 10^\circ, 15^\circ, 30^\circ, 45^\circ, 60^\circ, 75^\circ, 90^\circ$ ) digunakan sebagai data uji dengan jumlah citra  $20 \times 8 \times 24 = 3840$  citra.

uRLBP juga menghasilkan akurasi terbaik pada parameter ( $P=8,R=3$ ) dengan akurasi 88.01% untuk *dataset outex-12* yang terdiri dari 9120 citra 24 kelas tekstur setiap kelas tekstur terdiri dari 20 citra dan setiap citra dirotasi dengan

beberapa arah dan perbedaan pencahayaan. Data latih terdiri dari 480 citra, Sedangkan citra yang dirotasi dengan jumlah 8640 citra digunakan sebagai data uji.

## 2.6 Fuzzy *k*-Nearest Neighbor (Fuzzy *k*-NN)

Untuk mengklasifikasi fitur citra *pap smear* yang merupakan hasil penggabungan fitur bentuk dan fitur tekstur dari citra uji dan citra acuan digunakan metode *Fuzzy k-Nearest Neighbor* (Fuzzy *k*-NN). Algoritme *Fuzzy k*-NN diperkenalkan oleh Keller, dkk. (1985) dengan mengembangkan *k*-NN yang digabungkan dengan teori *Fuzzy* dalam menyampaikan definisi pemberian tabel kelas pada data uji yang diprediksi (Keller dkk., 1985).

Seperti halnya pada teori *Fuzzy*, sebuah data mempunyai nilai keanggotaan pada setiap kelas, yang artinya sebuah data bisa dimiliki oleh kelas yang berbeda dengan nilai derajat keanggotaan dalam interval [0,1]. Teori himpunan *Fuzzy* menggeneralisasi teori *k*-NN klasik dengan mendefinisikan nilai keanggotaan sebuah data pada masing-masing kelas. Formula yang digunakan (Li, 2007) adalah:

$$u(x, c_i) = \frac{\sum_{k=1}^K u(x_k - c_i) * d(x, x_k)^{\frac{-2}{(m-1)}}}{\sum_{k=1}^K d(x, x_k)^{\frac{-2}{(m-1)}}} \quad (2.6)$$

Dimana  $u(x, c_i)$  adalah nilai keanggotaan data kelas  $x$  ke kelas  $c_i$ ,  $k$  adalah jumlah tetangga terdekat yang digunakan.  $(x_k, c_i)$  adalah nilai keanggotaan data tetangga dalam  $k$  tetangga pada kelas  $c_i$ , nilainya 1 jika data latih  $x_k$  dimiliki kelas  $c_i$  atau 0 jika bukan dimiliki kelas  $c_i$ .  $d(x, x_k)$  adalah jarak dari data  $x$  ke data  $x_k$  dalam  $k$  tetangga terdekat.  $m$  adalah bobot pangkat (*weight exponent*) yang besarnya:  $m > 1$ .

Nilai keanggotaan pada suatu data sangat dipengaruhi oleh jarak data itu ke tetangga terdekatnya. Semakin dekat ke tetangganya, semakin besar nilai keanggotaan data tersebut pada kelas tetangganya, begitu pula sebaliknya. Jarak tersebut diukur dengan  $N$  dimensi (fitur) data.

Pengukuran jarak (ketidakmiripan) dua data yang digunakan dalam *Fuzzy k*-NN digeneralisasi dengan formula :

$$d(x_i, x_j) = \left( \sum_{i=1}^N |x_{i1} - x_{j1}|^p \right)^{\frac{1}{p}} \quad (2.7)$$

$N$  adalah dimensi jumlah fitur data.  $p$  adalah penentu jarak yang digunakan. Jika  $p=1$ , jarak yang digunakan adalah *Manhattan*. Jika  $p=2$ , jarak yang digunakan adalah *Euclidian*. Jika  $p = \infty$ , jarak yang digunakan adalah *Chebyshev*.

Meskipun *Fuzzy k-NN* menggunakan nilai keanggotaan untuk menyatakan keanggotaan data pada setiap kelas, untuk memberikan keluaran terakhir. *Fuzzy k-NN* harus tetap memberikan kelas akhir hasil prediksi. Untuk keperluan ini, *Fuzzy k-NN* memilih kelas dengan nilai keanggotaan terbesar pada data tersebut.

**ALGORITME – Prediksi *Fuzzy k-Nearest Neighbor***

1. Normalisasi data menggunakan nilai terbesar dan terkecil data pada setiap fitur.
2. Cari  $k$  tetangga terdekat untuk data uji  $x$  menggunakan persamaan 2.7
3. Hitung nilai keanggotaan  $u(x_i, c_i)$  menggunakan persamaan 2.6 untuk setiap  $i$ , dimana  $1 \leq i \leq c$ .
4. Ambil nilai terbesar  $c = u(x_i, c_i)$  untuk semua  $1 \leq i \leq c$ .
5. Berikan label kelas  $c$  ke data uji  $x$ .

Gambar 2.8. Algoritme Prediksi *Fuzzy k-Nearest Neighbor* (Prasetyo, 2012).

**2.7 Normalisasi Data**

Fitur dengan nilai atau jangkauan yang besar mempunyai pengaruh yang lebih besar dalam fungsi biaya daripada fitur dengan nilai atau jangkauan kecil. Untuk menangani ini, maka dilakukan normalisasi fitur sehingga semua fitur berada dalam jangkauan yang sama. Persamaan 2.8 merupakan perhitungan normalisasi fitur dalam jangkauan [0,1] (Prasetyo, 2014).

$$Fitur Hasil = \frac{fitur\ awal - \min(fitur\ awal)}{\max(fitur\ awal) - \min(fitur\ awal)} \tag{2.8}$$

**2.8 Akurasi Pengukuran Kinerja Klasifikator**

Sebuah sistem yang digunakan untuk mengklasifikasi diharapkan dapat melakukan klasifikasi semua set data dengan benar, tetapi tidak dapat dipungkiri bahwa kinerja suatu sistem tidak bisa 100% benar sehingga sebuah sistem

klasifikasi juga harus diukur kinerjanya. Umumnya, pengukuran kinerja klasifikasi dilakukan dengan matriks konfusi (*confusion matrix*).

Matrik konfusi merupakan suatu metode yang biasanya digunakan untuk melakukan perhitungan akurasi. Matrik konfusi merupakan tabel pencatat hasil kerja klasifikasi. Tabel 2.4 merupakan contoh matriks konfusi yang melakukan klasifikasi masalah biner (dua kelas), hanya ada dua kelas, yaitu kelas 0 dan 1. Setiap sel  $f_{ij}$  dalam matriks menyatakan jumlah rekod/data dari kelas  $i$  yang hasil prediksinya masuk ke kelas  $j$ . Misalnya,  $f_{11}$  adalah jumlah data dalam kelas 1 yang secara benar dipetakan ke kelas 1, dan  $f_{10}$  adalah data dalam kelas 1 yang dipetakan secara salah ke kelas 0.

Tabel 2.4 Contoh matriks konfusi untuk klasifikasi dua kelas (Prasetyo, 2012).

$f_{ij}$		Kelas hasil prediksi ( $j$ )	
		Kelas=1	Kelas=0
Kelas asli ( $i$ )	Kelas=1	$f_{11}$	$f_{10}$
	Kelas=0	$f_{01}$	$f_{00}$

Berdasarkan isi matriks konfusi, dapat diketahui jumlah data dari masing-masing kelas yang diprediksi secara benar, yaitu  $(f_{11} + f_{00})$ , dan data yang diklasifikasikan secara salah, yaitu  $(f_{10} + f_{01})$ . Kuantitas matriks konfusi dapat diringkas menjadi dua nilai, yaitu akurasi dan laju eror. Dengan mengetahui jumlah data yang diklasifikasikan secara benar, dapat mengetahui akurasi hasil prediksi, dan dengan mengetahui jumlah data yang diklasifikasikan secara salah, dapat mengetahui laju eror dari prediksi yang dilakukan. Dua kelas ini digunakan sebagai metrik kinerja klasifikasi. Persamaan 2.9 dan persamaan 2.10 menunjukkan perhitungan akurasi.

$$Akurasi = \frac{\text{jumlah data yang diprediksi secara benar}}{\text{jumlah prediksi yang dilakukan}} \times 100 \quad (2.9)$$

$$Akurasi = \frac{f_{10} + f_{01}}{f_{11} + f_{10} + f_{01} + f_{00}} \quad (2.10)$$

## 2.9 Metode Evaluasi Klasifikator

Metrik kinerja klasifikator memberikan nilai dari klasifikator. Nilai-nilai tersebut didapatkan dengan menguji *set* data yang ada. Untuk itu label kelas selama pengujian diketahui karena label kelas yang didapatkan dari prediksi harus dibandingkan dengan label kelas yang sebenarnya dimiliki oleh data yang diujikan tersebut. Dengan melakukan pengukuran kinerja model pada *set* data uji maka ukuran yang didapatkan memberikan perkiraan tidak bias dari generalisasi *error*. Akurasi atau *error* yang dihitung dari data uji juga bisa digunakan untuk membandingkan kinerja relatif dari klasifikator berbeda pada domain yang sama.

### 2.9.1 *K-Fold Cross Validation*

*K-fold cross validation* memecah *set* data menjadi  $k$  bagian set data dengan ukuran yang sama. Setiap kali berjalan, satu pecahan berperan sebagai *set* data latih sedangkan pecahan lainnya menjadi set data uji. Prosedur tersebut dilakukan sebanyak  $k$  kali sehingga setiap data berkesempatan menjadi data uji tepat satu kali dan menjadi data latih sebanyak  $k-1$  kali. Sedangkan total *error* didapatkan dengan menjumlah semua *error* yang didapatkan dari  $k$  kali proses (Prasetyo, 2014). Menurut Trevor (2008), dengan  $K=5$  atau  $K=10$  dapat digunakan untuk memperkirakan tingkat kesalahan yang terjadi, sebab data *training* pada setiap *fold* cukup berbeda dengan data *training* yang asli. Secara keseluruhan, *5-fold* atau *10-fold cross validation* sama-sama direkomendasikan dan disepakati bersama.

### 2.9.2 *Holdout*

Metode *holdout*, *set* data (yang sudah diketahui label kelas aslinya) dipecah menjadi dua bagian terpisah, yaitu *set* data latih dan *set* data uji. Metode klasifikasi kemudian dibangun berdasarkan *set* data latih dan kemudian kinerjanya diukur berdasarkan *set* data uji. Akurasi (metrik lain) dihitung berdasarkan hasil pengujian prediksi menggunakan *set* data uji pada model yang dibangun berdasarkan *set* data latih (Tan dkk, 2006).

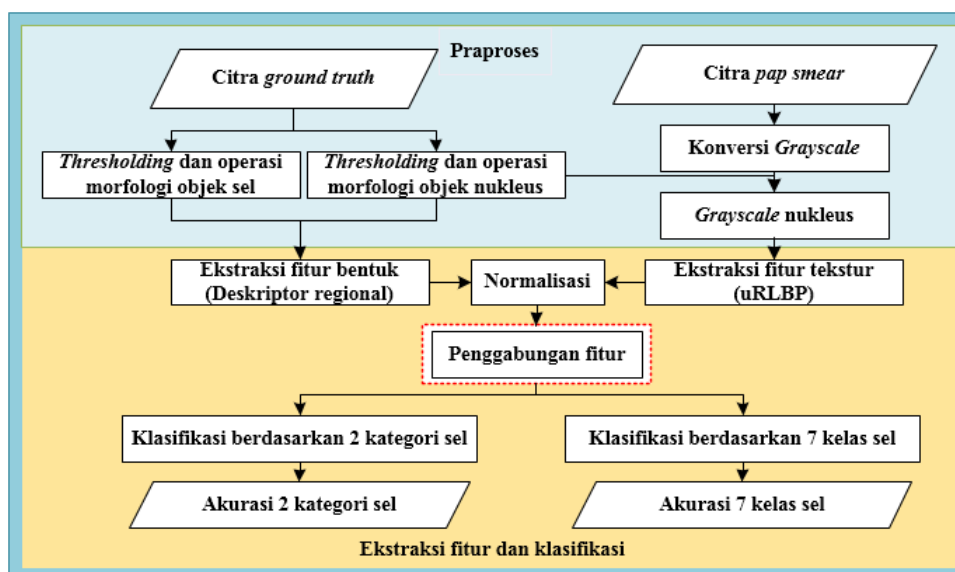
## BAB 3

### METODE PENELITIAN

Pada bab ini menjelaskan mengenai metodologi penelitian untuk merancang sistem klasifikasi sel serviks pada citra *pap smear* menggunakan kombinasi fitur bentuk deskriptor regional dan fitur tekstur *Uniform Rotated Local Binary Pattern* (uRLBP).

#### 3.1 Rancangan Sistem

Rancangan sistem klasifikasi sel serviks pada citra *pap smear* yang akan dibangun meliputi praproses, ekstraksi fitur berdasarkan kombinasi fitur bentuk dan fitur tekstur, dan tahap klasifikasi menggunakan metode *Fuzzy k-Nearest Neighbor* untuk klasifikasi dua kategori sel yaitu normal dan abnormal, serta tujuh kelas sel yaitu *normal squamous*, *intermediate squamous*, *columnar*, *mild dysplasia*, *moderate dysplasia*, *severe dysplasia*, dan *carcinoma in situ*. Kontribusi penelitian ini adalah kombinasi fitur bentuk berdasarkan deskriptor regional hasil ekstraksi area dan *compactness* dengan fitur tekstur hasil ekstraksi dari metode *Uniform Rotated Local Binary Pattern* yang menghasilkan fitur yang *invariant* terhadap rotasi.




Gambar 3.1 Rancangan sistem klasifikasi sel serviks pada citra *pap smear*.

Gambaran umum dari rancangan sistem klasifikasi sel serviks pada citra *pap smear* yang diusulkan pada penelitian ini ditunjukkan pada gambar 3.1.

### 3.1.1 Dataset


*Dataset* yang digunakan adalah *dataset* Herlev yang terdiri dari citra *pap smear* dalam bentuk tunggal atau satu sel (*single cell*) yang diakuisisi dan diidentifikasi oleh ahli sel terampil (*skilled cyto-technicians*) menggunakan mikroskop yang terkoneksi dengan sebuah *frame grabber*. *Dataset* terdiri dari 917 citra satu sel yang sudah dilakukan *cropping* oleh bagian patologi Rumah Sakit Herlev dan bagian *automation* pada *Technical University* Denmark (Mbaga, 2015). Citra diambil dengan resolusi 0.201  $\mu\text{m}$ /piksel dengan ukuran rata-rata citra 150 x 140 piksel (Mbaga, 2015). Semua citra diklasifikasikan oleh ahli sel ke dalam kategori diagnosis dan setiap citra diagnosis dibedakan ke dalam dua citra (Mbaga, 2015) yakni citra *pap smear* dan citra tersegmentasi. Setiap citra disegmentasi oleh ahli sel menggunakan *software* CHAMP untuk tujuan ekstraksi fitur (Norup, 2005). CHAMP adalah sistem analisis citra medis berdasarkan algoritme pengenalan (*recognition algorithm*) objek berwarna (Norup, 2005).



Gambar 3.2 Contoh citra *dataset* Herlev sel tunggal : (a) *normal squamous*, (b) *intermediate squamouse*, (c) *columnnar*, (d) *mild dysplasia*, (e) *moderate dysplasia*, (f) *severe dysplasia*, (g) dan *carcinoma in situ* (Mariarputham, 2015).



Untuk mendapatkan citra yang solid, semua citra disegmentasi ke dalam tiga bagian yaitu *background*, sitoplasma, dan nukleus (Norup, 2015). Gambar 3.2 menunjukkan contoh sel pada tujuh kelas *dataset* Herlev. Gambar 3.3 menunjukkan citra *pap smear* dan citra tersegmentasi, tabel 3.1 menunjukkan distribusi citra *pap smear*.



Gambar 3.3 Contoh citra *pap smear*, (a) citra warna dan (b) citra tersegmentasi (Norup, 2005).

Tabel 3.1 Distribusi jumlah sel *pap smear* (Mariarputham, 2015).


Kelas	Kategori	Tipe Sel	Jumlah Sel	Total
1	Normal	<i>Normal squamous</i>	74	242
2		<i>Intermediate squamous</i>	70	
3		<i>Columnar</i>	98	
4	Abnormal	<i>Mild Dysplasia</i>	182	675
5		<i>Moderate Dysplasia</i>	146	
6		<i>Severe Dysplasia</i>	197	
7		<i>Carcinoma in situ</i>	150	

### 3.1.2 Praproses

Semua citra yang akan dijadikan data uji maupun data latih (data acuan) akan melewati tahapan praproses yang sama. Setiap data memiliki dua citra yang berukuran sama. Citra pertama sebagai citra warna *pap smear* dan citra yang kedua adalah citra *ground truth*. Praproses terdiri dari dua bagian yakni praproses yang menghasilkan citra biner nukleus dan citra biner sel dan juga praproses yang menghasilkan citra *grayscale* nukleus. Citra biner nukleus dan citra biner sel akan

menjadi masukan pada proses ekstraksi fitur bentuk sedangkan citra *grayscale* nukleus akan menjadi masukan pada proses ekstraksi fitur tekstur.

Citra biner nukleus dan citra biner sel didapatkan dari citra *ground truth* yang sudah dilakukan proses segmentasi oleh ahli sel. Citra *ground truth* merupakan citra 2 dimensi bertipe *bitmap* yang mempunyai rentang nilai *grayscale* antara 0 sampai 4 dengan mengecualikan *color map*. Nilai *grayscale* 2 merupakan objek nukleus, nilai *grayscale* 1 sampai 3 merupakan objek sel, dan nilai *grayscale* 0 dan 4 adalah *background*. *Thresholding* diterapkan pada citra *ground truth* menggunakan pendekatan algoritme *multilevel thresholding* untuk mendapatkan citra biner nukleus dan citra biner sel. Untuk mendapatkan objek nukleus, nilai *grayscale* 2 dirubah menjadi nilai *grayscale* 1 dan nilai *grayscale* lainnya dirubah menjadi 0 sedangkan untuk mendapatkan objek sel, nilai *grayscale* 1 sampai 3 dirubah menjadi nilai *grayscale* 1 dan nilai *grayscale* lainnya dirubah menjadi 0. Setelah dilakukan *thresholding* untuk menangani *noise* di area citra dan *background* dengan menggunakan operasi morfologi *opening* dan *bwareaopen*. Gambar 3.4 menunjukkan tahapan praproses citra biner nukleus dan citra biner sel.




Gambar 3.4 Tahapan praproses citra biner nukleus dan citra biner sel.

Operasi morfologi digunakan untuk menghilangkan *noise* di area objek atau *background*. Operasi opening secara bertahap diterapkan pada citra hasil *thresholding* dengan perintah pada matlab  $imopen(I,x)$  dengan  $I$  merupakan citra hasil *thresholding* dan  $x=strel('disk',R)$ . *Strel* atau *structuring elements* adalah himpunan kecil atau sub-*image* yang digunakan untuk meneliti citra dalam pembelajaran propertinya. Menggunakan elemen penataan berbentuk *disk* sedangkan  $R$  adalah radius. Setelah dilakukan operasi dengan perintah  $imopen(I,x)$  selanjutnya dilakukan operasi dengan perintah  $bwareaopen(BW,P)$  dengan  $BW$  adalah citra hasil operasi  $imopen(I,x)$  dan  $P$  adalah luas piksel pembatas pada citra biner. Perintah  $bwareaopen$  digunakan untuk menghapus *noise* dari citra biner yang luasnya kurang dari  $P$  piksel. Tabel 3.2 menunjukkan penggunaan  $R$  pada  $strel('disk',R)$  dan penggunaan  $P$  pada  $bwareaopen(BW,P)$  untuk menghasilkan objek biner nukleus dan objek biner sel yang tidak mengandung *noise*.

Tabel 3.2 Penggunaan nilai  $R$  pada  $strel('disk',R)$  dan  $P$  pada  $bwareaopen(BW,P)$  untuk operasi morfologi citra *ground truth*.

Kelas	Objek Biner Nukleus		Objek Biner Sel	
	$R$	$P$	$R$	$P$
<i>Normal squamous</i>	2	20	5	20
<i>Intermediate squamous</i>	2	20	5	50
<i>Columnar</i>	2	20	5	1500
<i>Mild dysplasia</i>	2	20	5	1500
<i>Moderate dysplasia</i>	2	20	5	300
<i>Severe dysplasia</i>	2	50	5	1000
<i>Carcinoma in situ</i>	2	20	5	300

Praproses untuk masukan fitur tekstur menggunakan citra *ground truth* dan citra warna *pap smear*. Daerah nukleus pada citra *ground truth* yang telah mengalami operasi *thresholding* dan operasi *opening* merupakan citra biner nukleus yang akan dirubah intensitas *grayscale* dengan intensitas *grayscale* citra *pap smear*. Proses perubahan intensitas yakni citra biner nukleus dengan posisi piksel  $(x,y)$  bernilai *grayscale* 1 dirubah intensitasnya dengan nilai *grayscale* citra *pap smear* pada posisi koordinat yang sama. Gambar 3.5 Menunjukkan tahapan praproses citra *grayscale* nukleus.




Gambar 3.5 Tahapan praproses citra *grayscale* nukleus.

### 3.1.3 Kombinasi Fitur Bentuk Deskriptor Regional dan Fitur Tekstur *Uniform Rotated Local Binary Pattern (uRLBP)*

Deskriptor bentuk regional adalah deskriptor yang tidak berpengaruh terhadap orientasi objek yang dapat membedakan antara objek satu dengan objek lain dan dapat menjadi ciri antar kelas dalam mengklasifikasikan sel serviks pada citra *pap smear*. Karena ciri sebuah sel abnormal ditandai dengan adanya bentuk morfologi seperti area dan *compactness*. Citra biner hasil praproses akan mengalami ekstraksi fitur bentuk berdasarkan perhitungan deskriptor regional sederhana. Fitur bentuk pada daerah nukleus terdiri dari area nukleus dan *compactness* nukleus, sedangkan daerah pada keseluruhan sel adalah area sel dan *compactness* sel.


Perhitungan fitur bentuk secara berurutan terdiri dari hasil perhitungan area nukleus, *compactness* nukleus, area sel, dan *compactness* sel akan diletakkan pada 1 vektor bentuk berukuran 1 x 4. Untuk mendapatkan nilai fitur area menggunakan fungsi matlab *regionprops(BW,'Area')* sedangkan untuk mendapatkan nilai fitur *compactness* yakni kuadrat perimeter dibagi dengan area objek. Untuk mendapatkan nilai fitur *compactness* perlu dihitung nilai *perimeter* suatu objek dengan fungsi matlab *regionprops(BW,'Perimeter')*. Tahapan dari ekstraksi fitur bentuk dalam penelitian ini ditunjukkan pada gambar 3.6.



Gambar 3.6 Tahapan ekstraksi fitur bentuk deskriptor regional.

Deskriptor tekstur adalah deskriptor yang penting untuk mendeteksi setiap tahapan kanker. Konsep tekstur dapat dipahami sebagai distribusi spasial antar piksel di area lokal yang telah ditentukan agar mendapatkan ciri yang lebih unik dalam mengklasifikasikan sel. Untuk memperoleh fitur nukleus, digunakan citra masukan berupa citra *grayscale* nukleus yang didapatkan dari perubahan intensitas antara citra biner nukleus dan citra *grayscale pap smear* menjadi citra *grayscale* nukleus kemudian dilakukan ekstraksi fitur menggunakan metode *Uniform Rotated Local Binary Pattern* (uRLBP). Dengan tahapan, hasil perhitungan RLBP digunakan untuk perhitungan *uniform pattern* menjadi uRLBP untuk mendapatkan beberapa informasi instrinsik tekstur dan mempertahankan informasi orientasi lokal serta informasi diskriminatif citra. Pola biner lokal pada RLBP disebut *uniform* jika kode biner mengandung paling banyak dua transisi dari 0 ke 1 atau sebaliknya. Misalnya, pola 00011100, 01000000 adalah *uniform* karena kedua pola tersebut terdiri dari 2 transisi, sedangkan 00101000 dan 00011010 adalah tidak *uniform* karena mengandung 4 transisi. Pola *uniform* histogram diletakkan pada *bin* pertama sampai *bin* 58 dengan 58 kemungkinan pola *uniform* untuk delapan ketetanggaan, sedangkan pola yang tidak *uniform* diletakkan pada *bin* terakhir yakni *bin* ke 59 (Ahonen, 2009). Panjang fitur pada uRLBP dengan perhitungan  $P(P-1)+3$ . uRLBP dengan jumlah ketetanggaan melingkar piksel  $P=8$  yang digunakan pada penelitian

ini mempunyai panjang 59 fitur dengan perhitungan  $8(8-1)+3=59$ . Tahapan ekstraksi fitur tekstur dalam penelitian ini ditunjukkan pada gambar 3.7.



Gambar 3.7 Tahapan ekstraksi fitur tekstur uRLBP.

Kombinasi fitur dilakukan dengan penggabungan nilai fitur area dan *compactness* dengan fitur tekstur dalam satu fitur vektor yang sama. Empat fitur pertama merupakan fitur area dan *compactness* dan fitur kelima sampai terakhir merupakan fitur tekstur yang terdiri dari 59 fitur untuk  $uRLBP(P=8,R=1)$ ,  $uRLBP(P=8,R=2)$  atau  $uRLBP(P=8,R=3)$ , sehingga jumlah fitur penggabungan adalah 63 fitur. Hasil kombinasi fitur bentuk dan fitur tekstur akan digunakan pada proses klasifikasi sel serviks pada citra *pap smear*. Jika terdapat sejumlah  $t$  citra, maka jumlah fitur yang dihasilkan berupa matriks berukuran  $(t \times 63)$ .

### 3.1.4 Klasifikasi Sel Serviks pada Citra *Pap Smear*

Klasifikasi sel serviks pada citra *pap smear* dilakukan dengan cara mencocokkan fitur data uji dengan fitur data latih (citra acuan) menggunakan metode klasifikasi *Fuzzy k-Nearest Neighbor (Fuzzy k-NN)*. Alasan menggunakan *Fuzzy k-NN* adalah kemampuannya dalam menentukan kelas. Algoritme ini mampu mempertimbangkan jika ada sifat ambigu dari tetangga lain (Prasetyo, 2012). Nilai bobot pada masing-masing kelas berdasarkan jarak akan dihitung kemudian dipilih kelas yang memiliki nilai maksimum. Kelas yang memiliki nilai maksimum

tersebut merupakan hasil klasifikasi kelas citra uji. Dasar penggunaan nilai  $k$  adalah jarak minimum dari data baru ke sampel data latih untuk menentukan  $k$  tetangga terdekat dan nilai  $k$  yang tinggi akan mengurangi efek *noise* klasifikasi (Rahmawati, 2016). Nilai  $k$  dibatasi sampai dengan  $k=14$  untuk mendapatkan hasil akurasi klasifikasi terbaik pada penelitian ini.

Klasifikasi sel serviks pada citra *pap smear* dilakukan dengan dua kategori, yaitu klasifikasi dua kategori sel dan klasifikasi tujuh kelas sel. Untuk mengevaluasi sistem klasifikasi yang dibangun berdasarkan kombinasi fitur bentuk dan fitur tekstur yang *invariant* terhadap rotasi maka akan dilakukan pengujian. Pengujian dilakukan dengan mencocokkan citra data uji dengan citra acuan berdasarkan fitur hasil kombinasi, kemudian dihitung akurasi klasifikasi kelas. Akurasi diperoleh dengan menghitung jumlah dari pengenalan citra uji yang diklasifikasikan dengan benar. Perhitungan akurasi menggunakan persamaan (2.9).

### 3.2 Uji Coba dan Analisis

Evaluasi terhadap hasil dan performa metode yang diimplementasikan dilakukan melalui perhitungan akurasi. Evaluasi klasifikasi dilakukan berdasarkan metode *k-fold cross validation* dan *holdout*. Sebelum dilakukan evaluasi melalui perhitungan akurasi, data fitur akan dinormalisasi terlebih dahulu menggunakan persamaan (2.8). Pada tahapan ini juga dilakukan analisis terhadap parameter-parameter yang optimal pada metode ekstraksi fitur tekstur uRLBP yaitu parameter  $(P,R)$  dan juga parameter  $k$  pada metode klasifikasi *Fuzzy k-NN* yang menghasilkan akurasi optimal. Untuk melakukan analisis ini, dilakukan uji coba sebagai berikut.

- a. Uji coba I : Evaluasi parameter fitur tekstur dengan *k-fold cross validation*. Setiap citra hasil praproses akan diekstraksi fitur teksturnya. Fitur tekstur akan diuji untuk mengklasifikasikan sel serviks pada citra *pap smear* ke dalam dua kategori sel dan tujuh kelas sel pada citra yang dirotasi  $0^\circ$  yang berjumlah 917 citra menggunakan metode uRLBP dengan variasi jumlah ketetanggaan  $P$  tetap dan radius  $R$  berbeda  $(P=8,R=1)$ ,  $(P=8,R=2)$ , dan  $(P=8,R=3)$ . Nilai  $k$  pada *Fuzzy k-NN* yang digunakan yaitu  $k=2$  sampai dengan  $k=14$  dan nilai  $k$  pada *k-fold cross validation* adalah  $k=10$ . Citra rotasi  $0^\circ$  dapat diasumsikan sebagai citra acuan. Tujuan dari uji coba ini digunakan

untuk mengetahui parameter  $(P,R)$  pada uRLBP dan parameter  $k$  pada *Fuzzy*  $k$ -NN yang menghasilkan akurasi terbaik pada klasifikasi fitur tekstur untuk citra rotasi  $0^\circ$ .

- b. Uji coba II : Evaluasi fitur tekstur yang *invariant* terhadap rotasi. Melakukan uji coba dengan hanya menggunakan fitur tekstur yang telah dirotasi dengan sudut  $0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ,$  dan  $315^\circ$ . Sudut terkecil rotasi citra adalah  $0^\circ$  mengacu pada penelitian (Mehta, 2013; Mehta, 2016) dan semua citra dengan nilai rotasi  $0^\circ$  yang berjumlah 917 citra digunakan sebagai data latih sisanya digunakan sebagai data uji berjumlah 6419 citra. Seluruh citra yang telah dirotasi  $0^\circ$  sampai dengan  $315^\circ$  berjumlah 7336 citra dan dievaluasi dengan metode *holdout*. Pengujian dilakukan untuk klasifikasi dua kategori sel dan tujuh kelas sel. Dengan nilai parameter  $k$  pada *Fuzzy*  $k$ -NN yang digunakan yaitu  $k=2$  sampai dengan  $k=14$  serta parameter uRLBP yaitu  $(P=8,R=1), (P=8,R=2),$  dan  $(P=8,R=3)$ . Tujuan dari uji coba ini digunakan untuk mengetahui parameter  $(P,R)$  pada uRLBP dan parameter  $k$  pada *Fuzzy*  $k$ -NN yang menghasilkan akurasi terbaik pada klasifikasi fitur tekstur yang *invariant* terhadap rotasi.
- c. Uji coba III : Evaluasi fitur bentuk yang *invariant* terhadap rotasi. Melakukan uji coba dengan hanya menggunakan fitur bentuk yang telah dirotasi dengan sudut  $0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ,$  dan  $315^\circ$ . Sudut terkecil rotasi citra adalah  $0^\circ$  mengacu pada penelitian (Mehta, 2013; Mehta, 2016) dan semua citra dengan nilai rotasi  $0^\circ$  yang berjumlah 917 citra digunakan sebagai data latih sisanya digunakan sebagai data uji berjumlah 6419 citra. Seluruh citra yang telah dirotasi  $0^\circ$  sampai dengan  $315^\circ$  berjumlah 7336 citra dan dievaluasi dengan metode *holdout*. Pengujian dilakukan untuk klasifikasi dua kategori sel dan tujuh kelas sel. Dengan nilai parameter  $k$  pada *Fuzzy*  $k$ -NN yang digunakan yaitu  $k=2$  sampai dengan  $k=14$  serta parameter uRLBP yaitu  $(P=8,R=1), (P=8,R=2),$  dan  $(P=8,R=3)$ . Tujuan dari uji coba ini digunakan untuk mengetahui parameter  $(P, R)$  pada uRLBP dan parameter  $k$  pada *Fuzzy*  $k$ -NN yang menghasilkan akurasi terbaik pada klasifikasi fitur bentuk yang *invariant* terhadap rotasi.



- d. Uji Coba IV : Evaluasi kombinasi fitur yang *invariant* terhadap rotasi. Melakukan uji coba menggunakan penggabungan fitur bentuk dan fitur tekstur yang telah dirotasi dengan sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ,  $180^\circ$ ,  $225^\circ$ ,  $270^\circ$ , dan  $315^\circ$ . Citra dengan rotasi sudut  $0^\circ$  digunakan sebagai data latih berjumlah 917 citra dan sisanya digunakan sebagai data uji berjumlah 6419 citra. Pengujian dilakukan untuk klasifikasi dua kategori sel dan tujuh kelas sel. Nilai parameter  $k$  pada *Fuzzy k-NN* yang digunakan yaitu  $k=2$  sampai dengan  $k=14$  serta parameter uRLBP yaitu  $(P=8,R=1)$ ,  $(P=8,R=2)$ , dan  $(P=8,R=3)$ . Tujuan dari uji coba ini digunakan untuk mengetahui parameter  $(P, R)$  pada uRLBP dan parameter  $k$  pada *Fuzzy k-NN* yang menghasilkan akurasi optimal. Parameter  $(P,R)$  dan parameter  $k$  yang menghasilkan akurasi terbaik akan digunakan untuk perbandingan metode dengan metode penggabungan sebelumnya.
- e. Uji coba V : Evaluasi hasil klasifikasi menggunakan fitur yang *invariant* terhadap rotasi berdasarkan kombinasi fitur bentuk deskriptor regional dan fitur tekstur *Uniform Rotated Local Binary Pattern* (uRLBP) dengan metode sebelumnya yakni kombinasi fitur bentuk dan fitur tekstur Homogenitas *Gray Level Co-Occurrence Matrix* (GLCM)(Chankong, 2014), fitur bentuk deskriptor regional dan fitur tekstur *Uniform Rotation Invariant Local Binary Pattern* (LBP<sup>riu</sup>)(Plissiti, 2011), serta fitur bentuk deskriptor regional dan fitur tekstur *Local Binary Pattern Histogram Fourier* (LBP-HF)(Pasrun, 2016). Tujuan dari uji coba ini untuk membandingkan akurasi antara metode kombinasi fitur yang diusulkan dengan metode kombinasi fitur sebelumnya.

**[Halaman ini sengaja dikosongkan]**

## BAB 4

### HASIL DAN PEMBAHASAN


Pada bab ini menjelaskan mengenai hasil uji coba dan pembahasan dari penelitian yang telah dilakukan. Berdasarkan uji coba maka akan dilakukan proses analisis untuk mengetahui beberapa hal yang akan menjadi kesimpulan dari penelitian ini.

#### 4.1 Lingkungan Uji Coba


Untuk uji coba pada penelitian ini, sistem klasifikasi sel serviks pada citra *pap smear* diimplementasikan dengan menggunakan perangkat lunak Matlab R2013a dan beberapa *library* yang tersedia. Adapun uji coba sistem digunakan PC dengan spesifikasi prosesor berjenis AMD E-450 + HD6320 1.6 GHz, memori berkapasitas 4 GB dan kapasitas *harddisk* sebesar 320 GB.

#### 4.2 Data Uji Coba


Pada penelitian ini, data uji coba yang digunakan adalah *dataset* Herlev. *Dataset* tersebut terdiri dari 917 citra dengan dua kategori sel yakni normal dan abnormal. Kategori normal terdiri dari tiga kelas sel dan kategori abnormal terdiri dari empat kelas sel. Setiap citra mempunyai citra *ground truth* yaitu citra yang sudah tersegmentasi oleh ahli sel.



Gambar 4.1 Contoh citra *grayscale* nukleus *carcinoma in situ* yang telah dirotasi.



Gambar 4.2 Contoh citra biner nukleus *carcinoma in situ* yang telah dirotasi.



Gambar 4.3 Contoh citra biner sel *carcinoma in situ* yang telah dirotasi.

Untuk keperluan uji coba, setiap citra akan dirotasi dalam delapan arah yaitu  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ,  $180^\circ$ ,  $225^\circ$ ,  $270^\circ$ , dan  $315^\circ$  berjumlah 7336 citra. Citra dengan rotasi  $0^\circ$  berjumlah 917 citra digunakan sebagai data latih (Mehta, 2013; Mehta, 2016) dan citra dengan rotasi  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ,  $180^\circ$ ,  $225^\circ$ ,  $270^\circ$ , dan  $315^\circ$  berjumlah 6419 citra digunakan sebagai data uji untuk pengujian fitur yang *invariant* terhadap rotasi. Untuk merotasi citra digunakan perintah *imrotate(I, -x, 'bicubic')* dengan *I* merupakan citra masukan, *x* adalah derajat putar, dan *bicubic* adalah metode interpolasi. Contoh citra yang telah mengalami proses rotasi ditunjukkan pada gambar 4.1, gambar 4.2, dan gambar 4.3.

Dalam sistem yang dibangun, semua citra *pap smear* dan citra *ground truth* akan mengalami tahap praproses sebelum melalui tahap ekstraksi fitur. Gambar 4.2 dan gambar 4.3 merupakan citra biner hasil praproses yang akan digunakan pada ekstraksi fitur bentuk sedangkan gambar 4.1 merupakan citra *grayscale* nukleus hasil praproses yang akan digunakan pada ekstraksi fitur tekstur.

### 4.3 Uji Coba

Pada tahap uji coba, sistem klasifikasi sel serviks pada citra *pap smear* yang dibangun akan diuji dengan mengklasifikasikan citra data uji berdasarkan citra data latih. Setelah diklasifikasi, akan dihitung besar akurasi dari jumlah data uji yang diklasifikasikan dengan benar.

Proses pengujian dilakukan pada 917 citra acuan yakni citra yang nilai rotasinya  $0^\circ$  dan 7336 citra yakni citra yang dirotasi 8 arah. Pengujian pada citra *pap smear* menggunakan metode *k-fold cross validation* untuk uji coba fitur tekstur terhadap citra yang dirotasi  $0^\circ$ , sedangkan pada citra yang dirotasi 8 arah menggunakan metode *holdout* untuk uji coba fitur yang *invariant* terhadap rotasi untuk fitur bentuk, fitur tekstur, kombinasi fitur, dan perbandingan metode kombinasi fitur. Metode klasifikasi untuk pengujian *k-fold cross validation* dan *holdout* menggunakan *Fuzzy k-Nearest Neighbor*. Untuk menghitung akurasi, digunakan persamaan (2.9) dan persamaan (2.10). Sebelum dilakukan pengujian, setiap data hasil ekstraksi fitur akan dinormalisasi pada setiap fiturnya menggunakan persamaan (2.8). Pengujian akurasi akan dilakukan dengan dua kategori untuk uji coba fitur pada citra acuan atau fitur yang *invariant* terhadap rotasi. Pengujian yang pertama adalah klasifikasi berdasarkan dua kategori sel yakni normal dan abnormal sedangkan pengujian yang kedua dilakukan untuk klasifikasi tujuh kelas sel yaitu *normal squamous*, *intermediate squamous*, *columnar*, *mild dysplasia*, *moderate dysplasia*, *severe dysplasia*, dan *carcinoma in situ*. Untuk pengujian kategori pada *dataset* diasumsikan sebagai kelas sehingga pengujian yang dilakukan adalah klasifikasi dua kategori sel (dua kelas) dan klasifikasi tujuh kelas sel.

Terdapat beberapa uji coba yang dilakukan dalam penelitian ini untuk menganalisis kehandalan hasil kombinasi fitur yang diusulkan, yaitu uji coba

pengaruh parameter ketetanggaan melingkar  $P$  dan radius  $R$  pada fitur tekstur untuk klasifikasi fitur tektur dan kombinasi fitur, pengaruh setiap fitur yaitu fitur tekstur, fitur bentuk, dan kombinasi fitur bentuk dan fitur tekstur dalam menghasilkan fitur yang *invariant* terhadap rotasi untuk klasifikasi sel serviks pada citra *pap smear*.

#### **4.3.1 Uji Coba Fitur Tekstur Citra Acuan untuk Klasifikasi Sel Serviks pada Citra *Pap Smear***

Pada bagian ini, akan dilakukan uji coba fitur tekstur citra acuan yakni citra yang dirotasi  $0^\circ$  berjumlah 917 citra. Tujuan uji coba ini adalah untuk mengetahui akurasi terbaik berdasarkan nilai pasangan parameter  $(P,R)$  pada metode ekstraksi fitur tekstur uRLBP dan parameter  $k$  pada metode klasifikasi *Fuzzy k-NN* untuk klasifikasi sel serviks pada citra *pap smear* dua kategori sel dan tujuh kelas sel. Parameter  $(P,R)$  pada uRLBP yang diujikan adalah  $(P=8,R=1)$ ,  $(P=8,R=2)$ , dan  $(P=8,R=3)$ . Penggunaan variasi parameter  $(P,R)$  pada uRLBP mengacu pada penelitian (Mehta, 2013). Ketiga variasi  $(P,R)$  tersebut mempunyai panjang fitur yang sama yakni 59 fitur tekstur.

Citra *input* merupakan citra *grayscale* nukleus yang dihasilkan dari proses perubahan intensitas antara citra biner nukleus dan citra *grayscale pap smear*. Ekstraksi fitur citra *grayscale* nukleus dilakukan menggunakan metode *Uniform Rotated Local Binary Pattern* (uRLBP) dengan variasi nilai parameter  $(P,R)$ . Hasil ekstraksi fitur uRLBP akan dinormalisasi pada setiap fiturnya dengan menggunakan persamaan (2.8) dan dievaluasi dengan cara mengklasifikasikan fitur citra data uji menggunakan *Fuzzy k-NN* dengan pengujian *k-fold cross validation* dengan *10-fold*. Menurut Trevor (2008), nilai  $k=10$  pada *k-fold cross validation* dapat digunakan untuk memperkirakan tingkat kesalahan yang terjadi, sebab data training pada setiap *fold* cukup berbeda dengan data training yang asli dan secara keseluruhan *10-fold cross validation* direkomendasikan dan disepakati bersama. Parameter *Fuzzy k-NN* yang digunakan untuk keseluruhan uji coba dalam penelitian ini menggunakan nilai parameter  $k=2$  sampai dengan  $k=14$ . Hasil akurasi diperoleh dengan menghitung jumlah citra data uji yang diprediksi benar menggunakan persamaan (2.9).

Tabel 4.1 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) pada citra acuan dengan 10-fold cross validation.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	790	127	86.15
3	786	131	85.71
4	799	118	87.13
5	794	123	86.59
6	798	119	87.02
7	798	119	87.02
8	802	115	87.46
<b>9</b>	<b>803</b>	<b>114</b>	<b>87.57</b>
10	799	118	87.13
11	802	115	87.46
12	801	116	87.35
13	801	116	87.35
14	797	120	86.91

Tabel 4.1 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan fitur tekstur uRLBP dengan nilai parameter ( $P=8,R=1$ ) menunjukkan akurasi optimal yakni 87.57% ketika parameter  $k=9$  pada metode klasifikasi Fuzzy  $k$ -NN menggunakan evaluasi  $k$ -fold cross validation dengan 10-fold. Dari 917 jumlah data uji, sebanyak 803 data yang diklasifikasikan dengan benar dan 114 data yang diklasifikasikan dengan salah.

Tabel 4.2 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) pada citra acuan dengan 10-fold cross validation.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	778	139	84.84
3	801	116	87.35
4	797	120	86.91
5	796	121	86.80
6	799	118	87.13
7	801	116	87.35
8	801	116	87.35
<b>9</b>	<b>807</b>	<b>110</b>	<b>88.00</b>
10	804	113	87.68
11	796	121	86.80
12	802	115	87.46
13	796	121	86.80
14	793	124	86.48

Tabel 4.2 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan fitur tekstur uRLBP dengan nilai parameter ( $P=8,R=2$ ) menunjukkan akurasi optimal yakni 88.00% ketika parameter  $k=9$  pada metode klasifikasi *Fuzzy k-NN* menggunakan evaluasi *k-fold cross validation* dengan 10-fold. Dari 917 jumlah data uji, sebanyak 807 data yang diklasifikasikan dengan benar dan 110 data yang diklasifikasikan dengan salah.

Tabel 4.3 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=3$ ) pada citra acuan dengan 10-fold cross validation.

<i>k Fuzzy k-NN</i>	Hasil Benar	Hasil Salah	Akurasi (%)
2	789	128	86.04
3	794	123	86.59
4	799	118	87.13
5	790	127	86.15
6	806	111	87.90
7	800	117	87.24
<b>8</b>	<b>807</b>	<b>110</b>	<b>88.00</b>
9	795	122	86.70
10	789	128	86.04
11	794	123	86.59
12	804	113	87.68
13	799	118	87.13
14	800	117	87.24

Tabel 4.3 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan fitur tekstur uRLBP dengan nilai parameter ( $P=8,R=3$ ) menunjukkan akurasi optimal yakni 88.00% ketika parameter  $k=8$  pada metode klasifikasi *Fuzzy k-NN* menggunakan evaluasi *k-fold cross validation* dengan 10-fold. Dari 917 jumlah data uji, sebanyak 807 data yang diklasifikasikan dengan benar dan 110 data yang diklasifikasikan dengan salah.

Dari 3 pengujian untuk dua kategori sel mengacu pada tabel 4.1, tabel 4.2, dan tabel 4.3, akurasi terbaik didapatkan ketika nilai parameter ( $P=8,R=2$ ) pada uRLBP dan nilai parameter  $k=9$  pada *Fuzzy k-NN* dan ketika nilai parameter ( $P=8,R=3$ ) pada uRLBP dan nilai parameter  $k=8$  pada *Fuzzy k-NN* yakni 88.00%. Dari 917 jumlah data uji, sebanyak 807 data yang diklasifikasikan dengan benar dan 110 data yang diklasifikasikan dengan salah.



Tabel 4.4 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) pada citra acuan dengan *10-fold cross validation*.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	393	524	42.86
3	380	537	41.44
4	385	532	41.98
5	386	531	42.09
6	393	524	42.86
7	413	504	45.04
8	421	496	45.91
9	409	508	44.60
10	415	502	45.26
11	414	503	45.15
12	416	501	45.37
<b>13</b>	<b>428</b>	<b>489</b>	<b>46.67</b>
14	421	496	45.91

Tabel 4.4 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan fitur tekstur uRLBP dengan nilai parameter ( $P=8,R=1$ ) menunjukkan akurasi optimal yakni 46.67% ketika parameter  $k=13$  pada metode klasifikasi *Fuzzy  $k$ -NN* menggunakan evaluasi *k-fold cross validation* dengan *10-fold*. Dari 917 jumlah data uji, sebanyak 428 data yang diklasifikasikan dengan benar dan 489 data yang diklasifikasikan dengan salah.

Tabel 4.5 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) pada citra acuan dengan *10-fold cross validation*.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	374	543	40.79
3	380	537	41.44
4	413	504	45.04
5	398	519	43.40
6	412	505	44.93
7	409	508	44.60
8	404	513	44.06
9	414	503	45.15
<b>10</b>	<b>422</b>	<b>495</b>	<b>46.02</b>
11	420	497	45.80
12	412	505	44.93
13	410	507	44.71
14	414	503	45.15

Tabel 4.5 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan fitur tekstur uRLBP dengan nilai parameter ( $P=8,R=2$ ) menunjukkan akurasi optimal yakni 46.02% ketika parameter  $k=10$  pada metode klasifikasi *Fuzzy k-NN* menggunakan evaluasi *k-fold cross validation* dengan 10-fold. Dari 917 jumlah data uji, sebanyak 422 data yang diklasifikasikan dengan benar dan 495 data yang diklasifikasikan dengan salah.

Tabel 4.6 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=3$ ) pada citra acuan dengan 10-fold cross validation.

<i>k Fuzzy k-NN</i>	Hasil Benar	Hasil Salah	Akurasi (%)
2	399	518	43.51
3	407	510	44.38
4	403	514	43.95
5	399	518	43.51
6	421	496	45.91
7	411	506	44.82
<b>8</b>	<b>424</b>	<b>493</b>	<b>46.24</b>
9	419	498	45.69
10	406	511	44.27
11	423	494	46.13
<b>12</b>	<b>424</b>	<b>493</b>	<b>46.24</b>
<b>13</b>	<b>424</b>	<b>493</b>	<b>46.24</b>
14	420	497	45.80

Tabel 4.6 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan fitur tekstur uRLBP dengan nilai parameter ( $P=8,R=3$ ) menunjukkan akurasi optimal yakni 46.24% ketika parameter  $k=8$ ,  $k=12$ , dan  $k=13$  pada metode klasifikasi *Fuzzy k-NN* menggunakan evaluasi *k-fold cross validation* dengan 10-fold. Dari 917 jumlah data uji, sebanyak 424 data yang diklasifikasikan dengan benar dan 493 data yang diklasifikasikan dengan salah.

Dari 3 pengujian untuk tujuh kelas sel mengacu pada tabel 4.4, tabel 4.5, dan tabel 4.6, akurasi terbaik didapatkan ketika nilai parameter ( $P=8,R=1$ ) pada uRLBP dan nilai parameter  $k=13$  pada *Fuzzy k-NN* yakni 46.67%. Dari 917 jumlah data uji, sebanyak 428 data yang diklasifikasikan dengan benar dan 489 data yang diklasifikasikan dengan salah.

Dari uji coba tersebut dapat disimpulkan bahwa akurasi terbaik untuk dua kategori sel berdasarkan fitur tekstur uRLBP yang diujikan pada citra acuan yakni 88.00% ketika nilai parameter ( $P=8, R=2$ ) pada uRLBP dan nilai parameter  $k=9$  pada *Fuzzy k-NN* dan ketika nilai parameter ( $P=8, R=3$ ) pada uRLBP dan nilai parameter  $k=8$  pada *Fuzzy k-NN*. Sebanyak 917 jumlah data uji, 807 data yang diklasifikasikan dengan benar dan 110 data yang diklasifikasikan dengan salah. Sedangkan akurasi terbaik untuk tujuh kelas sel didapatkan ketika nilai parameter ( $P=8, R=1$ ) pada uRLBP dan nilai parameter  $k=13$  pada *Fuzzy k-NN* yakni 46.67%. Sebanyak 917 jumlah data uji, 428 data yang diklasifikasikan dengan benar dan 489 data yang diklasifikasikan dengan salah.

#### **4.3.2 Uji Coba Fitur Tekstur yang *Invariant* terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra *Pap Smear***

Uji coba ini bertujuan untuk melihat pengaruh fitur tekstur terhadap hasil klasifikasi jika data uji merupakan data acuan dengan rotasi yang beragam dan juga melihat pengaruh parameter ( $P, R$ ) pada metode uRLBP untuk mendapatkan akurasi terbaik. Citra *input* merupakan citra *grayscale* daerah nukleus. Ekstraksi fitur citra *grayscale* nukleus akan dilakukan menggunakan metode uRLBP dengan parameter ( $P, R$ ) berbeda yakni ( $P=8, R=1$ ), ( $P=8, R=2$ ), dan ( $P=8, R=3$ ) yang menghasilkan 59 fitur. Hasil ekstraksi fitur uRLBP akan dinormalisasi menggunakan persamaan (2.8) dan dievaluasi dengan cara mengklasifikasikan fitur citra data uji menggunakan metode *Fuzzy k-NN* dengan pengujian *holdout*. Parameter *Fuzzy k-NN* yang digunakan adalah  $k=2$  sampai dengan  $k=14$  untuk mengetahui perubahan nilai akurasi dan akurasi optimal jika parameter  $k$  pada *Fuzzy k-NN* berbeda. Hasil akurasi diperoleh dengan menghitung jumlah citra data uji yang diklasifikasi benar menggunakan persamaan (2.9). Jumlah citra dalam pengujian ini adalah 7336 citra dengan perhitungan  $917 \times 8 = 7336$  citra. Nilai 8 adalah jumlah arah rotasi, rotasi  $0^\circ$  berjumlah  $1 \times 917 = 917$  citra, sedangkan rotasi dengan 7 arah yakni  $45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, \text{ dan } 315^\circ$  berjumlah  $7 \times 917 = 6419$  citra. Data latih yang digunakan adalah citra acuan yang berjumlah 917 citra yakni semua citra yang nilai rotasinya  $0^\circ$ . Sedangkan data uji merupakan data citra yang telah dirotasi ke dalam tujuh arah dengan jumlah 6419 citra.

Tabel 4.7 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) yang *invariant* terhadap rotasi.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	5378	1041	83.78
3	5462	957	85.09
4	5458	961	85.03
5	5484	935	85.43
6	5504	915	85.75
7	5514	905	85.90
8	5515	904	85.92
9	5511	908	85.85
10	5529	890	86.13
11	5532	887	86.18
12	5525	894	86.07
<b>13</b>	<b>5545</b>	<b>874</b>	<b>86.38</b>
14	5541	878	86.32

Tabel 4.7 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan fitur tekstur uRLBP yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=1$ ) menunjukkan akurasi optimal yakni 86.38% ketika parameter  $k=13$  pada metode klasifikasi Fuzzy  $k$ -NN dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 5545 data yang diklasifikasikan dengan benar dan 874 data yang diklasifikasikan dengan salah.

Tabel 4.8 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) yang *invariant* terhadap rotasi.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	5400	1019	84.13
3	5481	938	85.39
4	5451	968	84.92
5	5472	947	85.25
6	5477	942	85.32
7	5473	946	85.26
8	5484	935	85.43
9	5487	932	85.48
10	5510	909	85.84
11	5513	906	85.89
12	5511	908	85.85
<b>13</b>	<b>5518</b>	<b>901</b>	<b>85.96</b>
14	5513	906	85.89

Tabel 4.8 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan fitur tekstur uRLBP yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=2$ ) menunjukkan akurasi optimal yakni 85.96% ketika parameter  $k=13$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 5518 data yang diklasifikasikan dengan benar dan 901 data yang diklasifikasikan dengan salah.

Tabel 4.9 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=3$ ) yang *invariant* terhadap rotasi.

$k$ <i>Fuzzy k-NN</i>	Hasil Benar	Hasil Salah	Akurasi (%)
2	5461	958	85.08
3	5515	904	85.92
4	5501	918	85.70
5	5510	909	85.84
6	5490	929	85.53
7	5527	892	86.10
8	5519	900	85.98
9	5525	894	86.07
10	5534	885	86.21
11	5539	880	86.29
12	5540	879	86.31
13	5548	871	86.43
<b>14</b>	<b>5558</b>	<b>861</b>	<b>86.59</b>

Tabel 4.9 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan fitur tekstur uRLBP yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=3$ ) menunjukkan akurasi optimal yakni 86.59% ketika parameter  $k=14$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 5558 data yang diklasifikasikan dengan benar dan 861 data yang diklasifikasikan dengan salah.

Dari 3 pengujian untuk dua kategori sel berdasarkan fitur tekstur yang *invariant* terhadap rotasi mengacu pada tabel 4.7, tabel 4.8, dan tabel 4.9, akurasi terbaik didapatkan ketika nilai parameter ( $P=8,R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k-NN* yakni 86.59%. Dari 6419 jumlah data uji, sebanyak 5558 data yang diklasifikasikan dengan benar dan 861 data yang diklasifikasikan dengan salah.

Tabel 4.10 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ) yang *invariant* terhadap rotasi.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
<b>2</b>	<b>3747</b>	<b>2672</b>	<b>58.37</b>
3	3716	2703	57.89
4	3696	2723	57.58
5	3714	2705	57.86
6	3744	2675	58.33
7	3724	2695	58.02
8	3715	2704	57.88
9	3700	2719	57.64
10	3699	2720	57.63
11	3708	2711	57.77
12	3695	2724	57.56
13	3683	2736	57.38
14	3668	2751	57.14

Tabel 4.10 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan fitur tekstur uRLBP yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=1$ ) menunjukkan akurasi optimal yakni 58.37% ketika parameter  $k=2$  pada metode klasifikasi Fuzzy  $k$ -NN dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 3747 data yang diklasifikasikan dengan benar dan 2672 data yang diklasifikasikan dengan salah.

Tabel 4.11 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) yang *invariant* terhadap rotasi.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	3761	2658	58.59
<b>3</b>	<b>3787</b>	<b>2632</b>	<b>59.00</b>
4	3708	2711	57.77
5	3728	2691	58.08
6	3711	2708	57.81
7	3709	2710	57.78
8	3716	2703	57.89
9	3699	2720	57.63
10	3713	2706	57.84
11	3703	2716	57.69
12	3688	2731	57.45
13	3698	2721	57.61
14	3705	2714	57.72

Tabel 4.11 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan fitur tekstur uRLBP yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8, R=2$ ) menunjukkan akurasi optimal yakni 59.00% ketika parameter  $k=3$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 3787 data yang diklasifikasikan dengan benar dan 2632 data yang diklasifikasikan dengan salah.

Tabel 4.12 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8, R=3$ ) yang *invariant* terhadap rotasi.

$k$ <i>Fuzzy k-NN</i>	Hasil Benar	Hasil Salah	Akurasi (%)
<b>2</b>	<b>3767</b>	<b>2652</b>	<b>58.69</b>
3	3752	2667	58.45
4	3722	2697	57.98
5	3739	2680	58.25
6	3718	2701	57.92
7	3716	2703	57.89
8	3717	2702	57.91
9	3709	2710	57.78
10	3719	2700	57.94
11	3734	2685	58.17
12	3710	2709	57.80
13	3706	2713	57.73
14	3702	2717	57.67

Tabel 4.12 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan fitur tekstur uRLBP yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8, R=3$ ) menunjukkan akurasi optimal yakni 58.69% ketika parameter  $k=3$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 3767 data yang diklasifikasikan dengan benar dan 2652 data yang diklasifikasikan dengan salah.

Dari 3 pengujian untuk tujuh kelas sel mengacu pada tabel 4.10, tabel 4.11, dan tabel 4.12, akurasi terbaik didapatkan ketika nilai parameter ( $P=8, R=2$ ) pada uRLBP dan nilai parameter  $k=3$  pada *Fuzzy k-NN* yakni 59.00%. Dari 6419 jumlah data uji, sebanyak 3787 data yang diklasifikasikan dengan benar dan 2632 data yang diklasifikasikan dengan salah.

Dari uji coba tersebut dapat disimpulkan bahwa akurasi terbaik untuk dua kategori sel berdasarkan fitur tekstur uRLBP yang diujikan pada citra dirotasi 7 arah yakni 86.59% ketika nilai parameter ( $P=8, R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k-NN*. Sebanyak 6419 jumlah data uji, 5558 data yang diklasifikasikan dengan benar dan 861 data yang diklasifikasikan dengan salah. Sedangkan akurasi terbaik untuk tujuh kelas sel didapatkan ketika nilai parameter ( $P=8, R=2$ ) pada uRLBP dan nilai parameter  $k=3$  pada *Fuzzy k-NN* yakni 59.00%. Sebanyak 6419 jumlah data uji, 3787 data yang diklasifikasikan dengan benar dan 2632 data yang diklasifikasikan dengan salah.

#### **4.3.3 Uji Coba Fitur Bentuk yang *Invariant* terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra *Pap Smear***

Uji coba ini bertujuan untuk melihat pengaruh fitur bentuk terhadap hasil klasifikasi jika data uji merupakan data acuan dengan rotasi yang beragam seperti pada uji coba pengaruh fitur tekstur. Citra *input* merupakan citra biner daerah nukleus dan citra biner daerah sel. Ekstraksi fitur citra biner akan dilakukan menggunakan perhitungan deskriptor regional. Panjang fitur vektor bentuk yang dihasilkan adalah empat fitur. Empat fitur tersebut berturut-turut yaitu area nukleus, *compactness* nukleus, area sel, dan *compactness* sel. Fitur bentuk akan dinormalisasi pada setiap fiturnya dengan menggunakan persamaan (2.8). Hasil fitur yang telah dinormalisasi akan menjadi masukan dalam perhitungan akurasi menggunakan metode klasifikasi *Fuzzy k-NN* dan dievaluasi dengan cara mengklasifikasikan fitur citra data uji dengan pengujian *holdout*. Parameter *Fuzzy k-NN* yang digunakan adalah  $k=2$  sampai dengan  $k=14$  untuk mengetahui perubahan nilai akurasi dan akurasi optimal jika parameter  $k$  pada *Fuzzy k-NN* berbeda. Hasil akurasi diperoleh dengan menghitung jumlah citra data uji yang diklasifikasi benar menggunakan persamaan (2.9). Jumlah citra dalam pengujian ini adalah 7336 citra dengan perhitungan  $917 \times 8 = 7336$  citra. Nilai 8 adalah jumlah arah rotasi, rotasi  $0^\circ$  berjumlah  $1 \times 917=917$  citra, sedangkan rotasi dengan 7 arah yakni  $45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ,$  dan  $315^\circ$  berjumlah  $7 \times 917 = 6419$  citra. Data latih yang digunakan adalah citra acuan yang berjumlah 917 citra yakni semua



citra yang nilai rotasinya 0°. Sedangkan data uji merupakan data citra yang telah dirotasi ke dalam tujuh arah dengan jumlah 6419 citra.

Tabel 4.13 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur bentuk deskriptor regional yang *invariant* terhadap rotasi.

<i>k Fuzzy k</i> -NN	Hasil Benar	Hasil Salah	Akurasi (%)
<b>2</b>	<b>6409</b>	<b>10</b>	<b>99.84</b>
<b>3</b>	<b>6409</b>	<b>10</b>	<b>99.84</b>
4	6408	11	99.83
5	6408	11	99.83
6	6406	13	99.80
7	6407	12	99.81
8	6407	12	99.81
9	6407	12	99.81
10	6406	13	99.80
11	6405	14	99.78
12	6404	15	99.77
13	6404	15	99.77
14	6404	15	99.77

Tabel 4.14 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur bentuk deskriptor regional yang *invariant* terhadap rotasi.

<i>k Fuzzy k</i> -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	6333	86	98.66
3	6333	86	98.66
4	6333	86	98.66
5	6334	85	98.68
6	6333	86	98.66
7	6334	85	98.68
8	6336	83	98.71
9	6337	82	98.72
<b>10</b>	<b>6338</b>	<b>81</b>	<b>98.74</b>
<b>11</b>	<b>6338</b>	<b>81</b>	<b>98.74</b>
12	6336	83	98.71
13	6336	83	98.71
14	6334	85	98.68

Dari uji coba tersebut mengacu pada tabel 4.13 dan tabel 4.14 dapat disimpulkan bahwa akurasi optimal untuk dua kategori sel berdasarkan fitur bentuk deskriptor regional area dan *compactness* yang diujikan pada citra dirotasi 7 arah

yakni 99.84% ketika nilai parameter  $k=2$  dan  $k=3$  pada *Fuzzy k*-NN. Sebanyak 6419 jumlah data uji, 6409 data yang diklasifikasikan dengan benar dan 10 data yang diklasifikasikan dengan salah. Sedangkan akurasi optimal untuk tujuh kelas sel didapatkan ketika nilai parameter  $k=10$  dan  $k=11$  pada *Fuzzy k*-NN yakni 98.74%. Sebanyak 6419 jumlah data uji, 6338 data yang diklasifikasikan dengan benar dan 81 data yang diklasifikasikan dengan salah.

#### **4.3.4 Uji Coba Kombinasi Fitur Bentuk dan Fitur Tekstur yang *Invariant* terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra *Pap Smear***

Uji coba ini bertujuan untuk mengetahui pengaruh kombinasi fitur bentuk dan fitur tekstur terhadap hasil klasifikasi jika data uji merupakan data yang yang dirotasi beberapa arah seperti pada uji coba pengaruh fitur tekstur. Jumlah citra dalam pengujian ini adalah 7336 citra dengan perhitungan  $917 \times 8 = 7336$  citra. Nilai 8 adalah jumlah arah rotasi, rotasi  $0^\circ$  berjumlah  $1 \times 917 = 917$  citra, sedangkan rotasi dengan 7 arah yakni  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ ,  $180^\circ$ ,  $225^\circ$ ,  $270^\circ$ , dan  $315^\circ$  berjumlah  $7 \times 917 = 6419$  citra. Data latih yang digunakan adalah citra acuan yang berjumlah 917 citra yakni semua citra yang nilai rotasinya  $0^\circ$ . Sedangkan data uji merupakan data citra yang telah dirotasi ke dalam tujuh arah dengan jumlah 6419 citra.

Panjang fitur vektor gabungan berjumlah 63 fitur yang terdiri dari 4 fitur bentuk dan 59 fitur tekstur. Sebelum digabung fitur bentuk dan fitur tekstur akan dinormalisasi menggunakan persamaan (2.8) kemudian dilakukan proses kombinasi fitur. Hasil kombinasi fitur yang telah dinormalisasi akan menjadi masukan dalam perhitungan akurasi menggunakan metode klasifikasi *Fuzzy k*-NN. Parameter ekstraksi fitur tekstur ( $P,R$ ) pada uRLBP yang digunakan adalah ( $P=8,R=1$ ), ( $P=8,R=2$ ), dan ( $P=8,R=3$ ). Sedangkan parameter  $k$  pada metode klasifikasi *Fuzzy k*-NN yang digunakan adalah  $k=2$  sampai dengan  $k=14$  untuk mengetahui perubahan nilai akurasi dan akurasi optimal jika parameter  $k$  pada *Fuzzy k*-NN berbeda. Hasil akurasi diperoleh dengan menghitung jumlah citra data uji yang diklasifikasi benar menggunakan persamaan (2.9). Dari pengujian tersebut, nilai parameter ( $P,R$ ) pada metode ekstraksi fitur uRLBP serta  $k$  pada metode klasifikasi *Fuzzy k*-NN yang menghasilkan akurasi terbaik akan digunakan untuk perbandingan metode dengan metode kombinasi fitur sebelumnya.

Tabel 4.15 Hasil akurasi klasifikasi dua kategori sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=1$ ) pada uRLBP.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	5477	942	85.32
3	5667	752	88.28
4	5687	732	88.60
5	5667	752	88.28
6	5679	740	88.47
7	5715	704	89.03
8	5763	656	89.78
9	5764	655	89.80
10	5787	632	90.15
11	5819	600	90.65
12	5851	568	91.15
13	5871	548	91.46
<b>14</b>	<b>5875</b>	<b>544</b>	<b>91.53</b>

Tabel 4.15 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=1$ ) pada metode uRLBP menunjukkan akurasi optimal yakni 91.53% ketika parameter  $k=14$  pada metode klasifikasi Fuzzy  $k$ -NN dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 5875 data yang diklasifikasikan dengan benar dan 544 data yang diklasifikasikan dengan salah.

Tabel 4.16 Hasil akurasi klasifikasi dua kategori sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=2$ ) pada uRLBP.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	5483	936	85.42
3	5651	768	88.04
4	5691	728	88.66
5	5659	760	88.16
6	5675	744	88.41
7	5719	700	89.09
8	5759	660	89.72
9	5767	652	89.84
10	5775	644	89.97
11	5803	616	90.40
12	5843	576	91.03
<b>13</b>	<b>5875</b>	<b>544</b>	<b>91.53</b>
<b>14</b>	<b>5875</b>	<b>544</b>	<b>91.53</b>

Tabel 4.16 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=2$ ) pada metode uRLBP menunjukkan akurasi optimal yakni 91.53% ketika parameter  $k=13$  dan  $k=14$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 5875 data yang diklasifikasikan dengan benar dan 544 data yang diklasifikasikan dengan salah.

Tabel 4.17 Hasil akurasi klasifikasi dua kategori sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=3$ ) pada uRLBP.

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	5487	932	85.48
3	5663	756	88.22
4	5691	728	88.66
5	5683	736	88.53
6	5667	752	88.28
7	5699	720	88.78
8	5758	661	89.70
9	5771	648	89.90
10	5787	632	90.15
11	5811	608	90.53
12	5843	576	91.03
13	5867	552	91.40
<b>14</b>	<b>5879</b>	<b>540</b>	<b>91.59</b>

Tabel 4.17 menunjukkan hasil akurasi klasifikasi untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=3$ ) pada metode uRLBP menunjukkan akurasi optimal yakni 91.59% ketika parameter  $k=14$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 5879 data yang diklasifikasikan dengan benar dan 540 data yang diklasifikasikan dengan salah.

Dari 3 pengujian untuk dua kategori sel mengacu pada tabel 4.15, tabel 4.16, dan tabel 4.17, akurasi terbaik didapatkan ketika nilai parameter ( $P=8,R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k-NN* yakni 91.59%. Dari 6419 jumlah data uji, sebanyak 5879 data yang diklasifikasikan dengan benar dan 540 data yang diklasifikasikan dengan salah.

Tabel 4.18 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=1$ ) pada uRLBP

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	4187	2232	65.23
3	4239	2180	66.04
4	4259	2160	66.35
5	4327	2092	67.41
6	4307	2112	67.10
<b>7</b>	<b>4347</b>	<b>2072</b>	<b>67.72</b>
8	4326	2093	67.39
9	4334	2085	67.52
10	4322	2097	67.33
11	4318	2101	67.27
12	4310	2109	67.14
13	4280	2139	66.68
14	4317	2102	67.25

Tabel 4.18 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan kombinasi fitur bentuk dan fitur tekstur yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=1$ ) pada metode uRLBP menunjukkan akurasi optimal yakni 67.72% ketika parameter  $k=7$  pada metode klasifikasi Fuzzy  $k$ -NN dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 4347 data yang diklasifikasikan dengan benar dan 2072 data yang diklasifikasikan dengan salah.

Tabel 4.19 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=2$ ) pada uRLBP

$k$ Fuzzy $k$ -NN	Hasil Benar	Hasil Salah	Akurasi (%)
2	4171	2248	64.98
3	4223	2196	65.79
4	4271	2148	66.54
5	4327	2092	67.41
6	4307	2112	67.10
<b>7</b>	<b>4339</b>	<b>2080</b>	<b>67.60</b>
8	4326	2093	67.39
9	4326	2093	67.39
10	4321	2098	67.32
11	4310	2109	67.14
12	4314	2105	67.21
13	4294	2125	66.90
14	4338	2081	67.58

Tabel 4.19 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan kombinasi fitur bentuk dan fitur tekstur yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=2$ ) pada metode uRLBP menunjukkan akurasi optimal yakni 67.60% ketika parameter  $k=7$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 4339 data yang diklasifikasikan dengan benar dan 2080 data yang diklasifikasikan dengan salah.

Tabel 4.20 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan kombinasi fitur dengan parameter ( $P=8,R=3$ ) pada uRLBP

$k$ <i>Fuzzy k-NN</i>	Hasil Benar	Hasil Salah	Akurasi (%)
2	4171	2248	64.98
3	4215	2204	65.66
4	4271	2148	66.54
5	4335	2084	67.53
6	4311	2108	67.16
7	4343	2076	67.66
8	4322	2097	67.33
9	4350	2069	67.77
10	4322	2097	67.33
11	4322	2097	67.33
12	4330	2089	67.46
13	4308	2111	67.11
<b>14</b>	<b>4358</b>	<b>2061</b>	<b>67.89</b>

Tabel 4.20 menunjukkan hasil akurasi klasifikasi untuk tujuh kelas sel berdasarkan kombinasi fitur bentuk dan fitur tekstur yang *invariant* terhadap rotasi dengan nilai parameter ( $P=8,R=3$ ) pada metode uRLBP menunjukkan akurasi optimal yakni 67.89% ketika parameter  $k=14$  pada metode klasifikasi *Fuzzy k-NN* dengan evaluasi *holdout*. Dari 6419 jumlah data uji, sebanyak 4358 data yang diklasifikasikan dengan benar dan 2061 data yang diklasifikasikan dengan salah.

Dari 3 pengujian untuk tujuh kelas sel mengacu pada tabel 4.18, tabel 4.19, dan tabel 4.20, akurasi terbaik didapatkan ketika nilai parameter ( $P=8,R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k-NN* yakni 67.89%. Dari 6419 jumlah data uji, sebanyak 4358 data yang diklasifikasikan dengan benar dan 2061 data yang diklasifikasikan dengan salah.

Dari uji coba tersebut dapat disimpulkan bahwa akurasi terbaik untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur yang diujikan pada citra dirotasi 7 arah yakni 91.59% ketika nilai parameter ( $P=8,R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k*-NN. Sebanyak 6419 jumlah data uji, 5879 data yang diklasifikasikan dengan benar dan 540 data yang diklasifikasikan dengan salah. Sedangkan akurasi terbaik untuk tujuh kelas sel didapatkan ketika nilai parameter ( $P=8,R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k*-NN yakni 67.89%. Sebanyak 6419 jumlah data uji, 4358 data yang diklasifikasikan dengan benar dan 2061 data yang diklasifikasikan dengan salah. Parameter ( $P,R$ ) pada uRLBP dan parameter  $k$  pada *Fuzzy k*-NN yang menghasilkan nilai akurasi optimal untuk dua kategori sel dan tujuh kelas sel akan digunakan untuk perbandingan metode dengan kombinasi fitur sebelumnya.

#### **4.3.5 Uji Coba Perbandingan Metode Kombinasi Fitur dengan Metode Kombinasi Fitur Sebelumnya**

Uji coba ini bertujuan untuk membandingkan hasil uji coba metode kombinasi fitur usulan yang telah dilakukan dengan metode kombinasi fitur sebelumnya untuk mengetahui hasil akurasi kombinasi fitur bentuk dan fitur tekstur melalui perbandingan metode yang diusulkan dengan metode lain yang tidak *invariant* terhadap rotasi dan metode yang *invariant* terhadap rotasi.

Parameter *Fuzzy k*-NN yang digunakan untuk klasifikasi dua kategori sel adalah  $k=14$  dan parameter uRLBP adalah ( $P=8,R=3$ ). Sedangkan untuk klasifikasi tujuh kelas sel, parameter yang digunakan pada metode klasifikasi *Fuzzy k*-NN adalah  $k=14$  dan parameter yang digunakan untuk uRLBP adalah ( $P=8,R=3$ ). Ketentuan parameter ini diambil dari uji coba kombinasi fitur bentuk dan fitur tekstur yang diusulkan yang menghasilkan akurasi terbaik. Jumlah citra dalam pengujian ini adalah 7336 citra dengan perhitungan  $917 \times 8 = 7336$  citra. Nilai 8 adalah jumlah arah rotasi, rotasi  $0^\circ$  berjumlah  $1 \times 917=917$  citra, sedangkan rotasi dengan 7 arah yakni  $45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ$ , dan  $315^\circ$  berjumlah  $7 \times 917 = 6419$  citra. Data latih yang digunakan adalah citra acuan yang berjumlah 917 citra yakni semua citra yang nilai rotasinya  $0^\circ$ . Sedangkan data uji merupakan data citra yang telah dirotasi ke dalam tujuh arah dengan jumlah 6419 citra.

Metode kombinasi fitur sebelumnya yakni kombinasi fitur Bentuk dan fitur tekstur Homogenitas GLCM (Chankong, 2014) sebagai metode pembandingan pertama, kombinasi fitur bentuk dan fitur tekstur LBP<sup>riu</sup> (Plissiti, 2011) sebagai metode pembandingan kedua, dan kombinasi fitur Bentuk dan LBP-HF (Pasrun, 2016) sebagai metode pembandingan ketiga. Perbandingan metode dengan tiga metode lain ini memiliki perbedaan diantaranya, untuk kombinasi fitur pembandingan pertama menggunakan fitur vektor bentuk dengan 8 panjang fitur sesuai penelitian (Chankong, 2014) dan fitur tekstur Homogenitas GLCM, kombinasi fitur pembandingan kedua menggunakan fitur vektor bentuk dengan 4 panjang fitur dan fitur tekstur LBP<sup>riu</sup>, sedangkan untuk kombinasi fitur pembandingan ketiga menggunakan fitur vektor bentuk dengan 4 panjang fitur dan fitur tekstur LBP-HF. Delapan fitur bentuk (Chankong, 2014) yakni area nukleus, *compactness* nukleus, *major axis length* nukleus, *minor axis length* nukleus, aspek rasio nukleus, area sel, *compactness* sel, dan rasio *N/C*. Empat fitur bentuk pada metode yang diusulkan yakni area nukleus, *compactness* nukleus, area sel, dan *compactness* sel. Alasan kombinasi fitur pembandingan pertama menggunakan fitur bentuk dengan 8 panjang fitur vektor (Chankong, 2014) karena penelitian kombinasi tersebut menjadi rujukan untuk penggunaan fitur bentuk dalam metode yang diusulkan, sedangkan kombinasi fitur pembandingan lainnya menggunakan fitur bentuk sesuai dengan metode yang diusulkan yakni 4 panjang fitur vektor untuk perbandingan yang seimbang dengan metode usulan dalam penelitian ini.

Tabel 4.21, tabel 4.22, tabel 4.23, dan tabel 4.24, menunjukkan perbandingan kombinasi fitur untuk dua kategori sel dan tujuh kelas sel. Perbandingan akurasi pada tabel 4.21 dan tabel 4.23 menunjukkan bahwa kombinasi fitur yang diusulkan untuk dua kategori sel memiliki akurasi tertinggi yaitu 91.59% dibandingkan dengan tiga kombinasi fitur lainnya. Sebanyak, 6419 jumlah data uji, 5879 data diklasifikasikan dengan benar dan 540 data diklasifikasikan dengan salah. Metode sebelumnya yang dibandingkan merupakan metode yang menghasilkan fitur tekstur yang tidak *invariant* terhadap rotasi yaitu Homogenitas GLCM dan metode yang menghasilkan fitur tekstur yang *invariant* terhadap rotasi yaitu LBP<sup>riu</sup> dan LBP-HF. Perbandingan tersebut menghasilkan perbedaan akurasi antara kombinasi fitur yang diusulkan dengan kombinasi fitur



sebelumnya yakni Bentuk dan Homogenitas GLCM dengan selisih akurasi 5.72%, Bentuk dan LBP<sup>riu</sup> dengan selisih akurasi 0.19%, serta Bentuk dan LBP-HF dengan selisih akurasi 6.31%. Perbandingan akurasi hanya pada fitur bentuk yang diusulkan menurun dibandingkan dengan fitur bentuk yang diajukan oleh (Chankong, 2014), sedangkan perbandingan akurasi hanya pada fitur tekstur uRLBP lebih baik dibandingkan dengan Homogenitas GLCM dan LBP<sup>riu</sup>, namun menurun dibandingkan LBP-HF.

Tabel 4.21 Perbandingan kombinasi fitur dengan kombinasi fitur sebelumnya untuk klasifikasi dua kategori sel.

Fitur	<i>k=14 Fuzzy k-NN</i>		
	Hasil Benar	Hasil Salah	Akurasi (%)
Bentuk + Tekstur Homogenitas GLCM	5512	907	85.87
Bentuk + Tekstur LBP <sup>riu</sup> ( $P=8, R=3$ )	5867	552	91.40
Bentuk + Tekstur LBP-HF ( $P=8, R=3$ )	5474	945	85.28
Bentuk + Tekstur uRLBP ( $P=8, R=3$ )	5879	540	91.59

Tabel 4.22 Perbandingan kombinasi fitur dengan kombinasi fitur sebelumnya untuk klasifikasi tujuh kelas sel.

Fitur	<i>k=14 Fuzzy k-NN</i>		
	Hasil Benar	Hasil Salah	Akurasi (%)
Bentuk + Tekstur Homogenitas GLCM	2989	3430	46.56
Bentuk + Tekstur LBP <sup>riu</sup> ( $P=8, R=3$ )	4297	2122	66.94
Bentuk + Tekstur LBP-HF ( $P=8, R=3$ )	4229	2190	65.88
Bentuk + Tekstur uRLBP ( $P=8, R=3$ )	4358	2061	67.89

Tabel 4.23 Perbandingan metode dengan metode sebelumnya untuk klasifikasi dua kategori sel.

Fitur	Akurasi (%)		
	<i>k=14 Fuzzy k-NN</i>		
	Bentuk	Tekstur	Kombinasi
Bentuk + Tekstur Homogenitas GLCM	100.00	72.46	85.87
Bentuk + Tekstur LBP <sup>riu</sup> ( $P=8, R=3$ )	99.77	81.79	91.40
Bentuk + Tekstur LBP-HF ( $P=8, R=3$ )	99.77	88.27	85.28
Bentuk + Tekstur uRLBP ( $P=8, R=3$ )	99.77	86.59	91.59

Tabel 4.24 Perbandingan metode dengan metode sebelumnya untuk klasifikasi tujuh kelas sel.

Fitur	Akurasi (%)		
	<i>k=14 Fuzzy k-NN</i>		
	Bentuk	Tekstur	Kombinasi
Bentuk + Tekstur Homogenitas GLCM	99.78	25.19	46.56
Bentuk + Tekstur LBP <sup>riu</sup> ( $P=8, R=3$ )	98.68	35.92	66.94
Bentuk + Tekstur LBP-HF ( $P=8, R=3$ )	98.68	39.96	65.88
Bentuk + Tekstur uRLBP ( $P=8, R=3$ )	98.68	57.67	67.89

Perbandingan akurasi pada tabel 4.22 dan 4.24 menunjukkan bahwa kombinasi fitur yang diusulkan untuk tujuh kelas sel memiliki akurasi tertinggi yaitu 67.89% dibandingkan dengan tiga kombinasi fitur sebelumnya. Sebanyak, 6419 jumlah data uji, 4358 data diklasifikasikan dengan benar dan 2061 data diklasifikasikan dengan salah. Metode sebelumnya yang dibandingkan merupakan metode yang menghasilkan fitur yang tidak *invariant* terhadap rotasi yaitu Homogenitas GLCM dan metode yang menghasilkan fitur yang *invariant* terhadap rotasi yaitu LBP<sup>riu</sup> dan LBP-HF. Perbandingan tersebut menghasilkan perbedaan akurasi antara kombinasi fitur yang diusulkan dengan kombinasi fitur sebelumnya yakni kombinasi Bentuk dan Homogenitas GLCM dengan selisih akurasi 21.33%, kombinasi Bentuk dan LBP<sup>riu</sup> dengan selisih akurasi 0.95%, serta kombinasi Bentuk dan LBP-HF dengan selisih akurasi 2.01%. Perbandingan akurasi hanya pada fitur bentuk menurun dibandingkan dengan fitur bentuk yang diajukan oleh (Chankong, 2014), sedangkan perbandingan akurasi hanya pada fitur tekstur uRLBP lebih baik dibandingkan dengan Homogenitas GLCM, LBP<sup>riu</sup>, dan LBP-HF.

Tingginya akurasi hasil klasifikasi fitur bentuk deskriptor regional area dan *compactness* untuk dua kategori sel dan tujuh kelas sel dikarenakan tidak adanya *noise* pada citra biner nukleus dan citra biner sel. *Noise* pada citra biner dihilangkan dengan menggunakan operasi morfologi *opening* pada saat pra-proses. Sehingga kombinasi 4 fitur bentuk antara lain area nukleus, *compactness* nukleus, area sel, dan *compactness* sel dapat menghasilkan fitur yang *invariant* terhadap rotasi dengan akurasi yang tinggi. Rendahnya akurasi pada klasifikasi tujuh kelas sel yang ditunjukkan pada tabel 4.22 dan tabel 4.24 untuk fitur tekstur dan

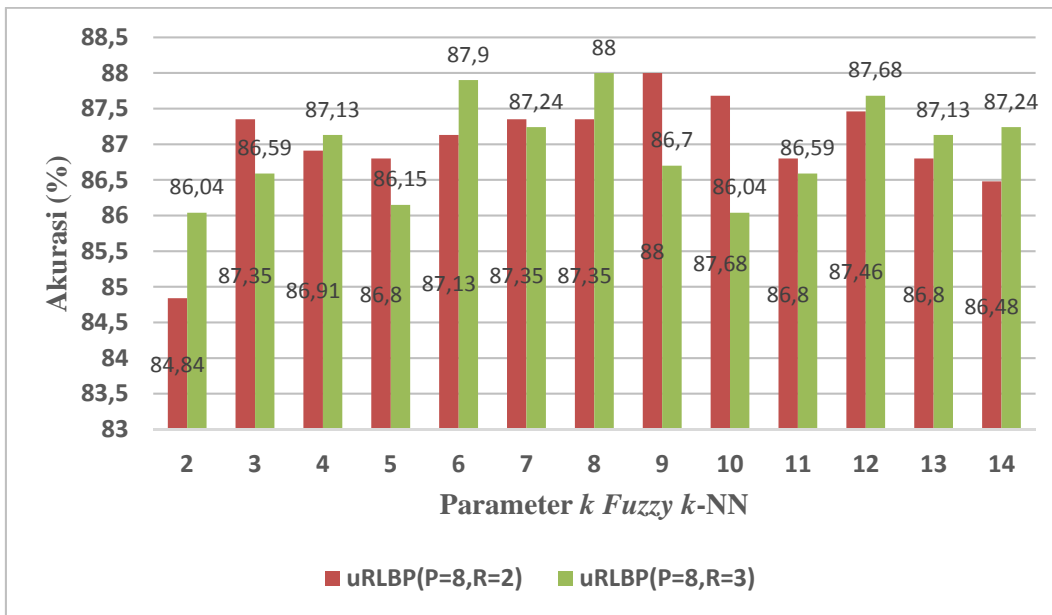
kombinasi fitur disebabkan karena pola fitur tekstur antar tujuh kelas memiliki kemiripan. Secara visual tekstur antar tujuh kelas memiliki karakteristik yang mirip yakni tekstur nukleus yang halus untuk semua kelas. Hal ini menjadikan pola fitur tekstur yang dihasilkan dari metode ekstraksi fitur uRLBP memiliki kemiripan dan mempengaruhi akurasi pada kombinasi fitur yang diusulkan.

Dari pengujian klasifikasi kombinasi fitur menggunakan metode *Fuzzy k-Nearest Neighbor* menunjukkan kehandalan metode yang diusulkan sehingga dapat disimpulkan bahwa akurasi pada metode kombinasi fitur untuk dua kategori sel dan tujuh kelas sel pada metode yang diusulkan memiliki akurasi lebih baik dibandingkan dengan akurasi tiga metode kombinasi fitur sebelumnya antara lain kombinasi fitur bentuk dan fitur tekstur Homogenitas GLCM (Chankong, 2014), kombinasi fitur bentuk dan fitur tekstur LBP<sup>riu</sup> (Plissiti, 2011), dan kombinasi fitur bentuk dan fitur tekstur LBP-HF (Pasrun, 2016).

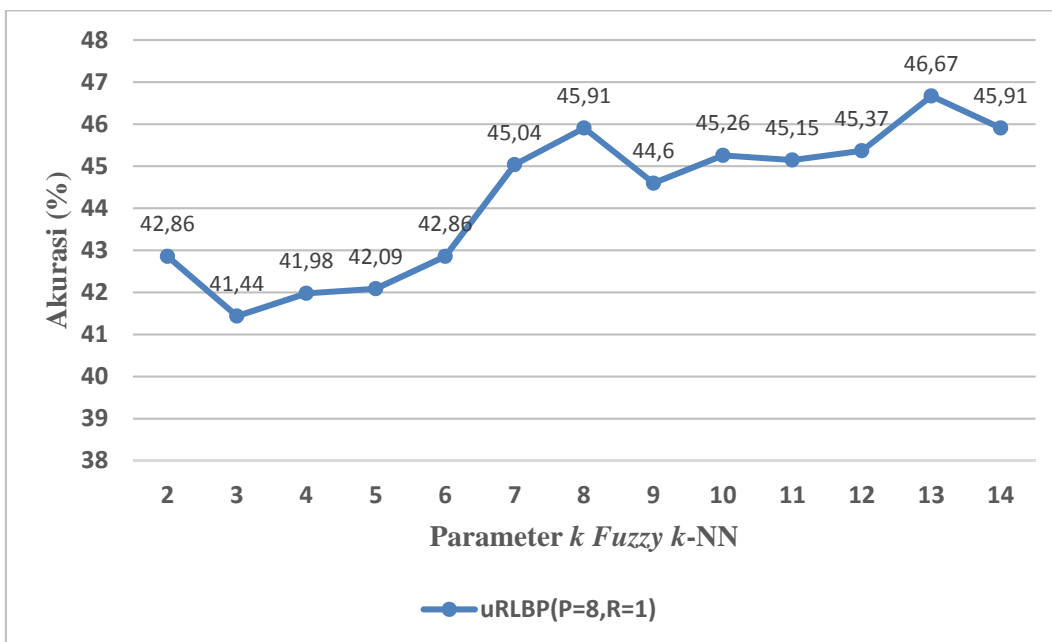
#### **4.4 Pembahasan Hasil Uji Coba**

##### **4.4.1 Fitur Tekstur Citra Acuan untuk Klasifikasi Sel Serviks pada Citra *Pap Smear***

Bagian ini membahas hasil pengujian klasifikasi citra *pap smear* dengan hanya menggunakan fitur tekstur terhadap citra acuan yakni citra yang dirotasi 0°. Pada proses pengujian klasifikasi dua kategori sel dengan menggunakan variasi  $(P,R)$  pada uRLBP yakni  $(P=8,R=1)$ ,  $(P=8,R=2)$ , dan  $(P=8,R=3)$  diperoleh rata-rata akurasi yakni 86.99%, 87.00%, dan 86.96% yang diklasifikasikan menggunakan *Fuzzy k-NN* dengan parameter  $k=2$  sampai dengan  $k=14$ . Rata-rata akurasi klasifikasi dari tiga pengujian variasi  $(P,R)$  pada uRLBP memiliki akurasi yang tidak jauh berbeda. Dari tiga pengujian klasifikasi tersebut didapatkan akurasi optimal yakni 87.57% , 88.00%, dan 88.00%. Akurasi terbaik dari tiga pengujian tersebut didapatkan ketika nilai parameter  $(P=8,R=2)$  pada uRLBP dan  $k=9$  pada *Fuzzy k-NN* serta  $(P=8,R=3)$  pada uRLBP dan  $k=8$  pada *Fuzzy k-NN* dengan akurasi klasifikasi mencapai 88.00%. Gambar 4.4 menunjukkan pengujian klasifikasi dua kategori sel citra *pap smear* menggunakan fitur tekstur uRLBP  $(P=8,R=2)$  dan uRLBP  $(P=8,R=3)$ .



Gambar 4.4 Akurasi klasifikasi citra acuan dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=2$ ) dan uRLBP ( $P=8,R=3$ )



Gambar 4.5 Akurasi klasifikasi citra acuan tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ).

Pada proses pengujian klasifikasi tujuh kelas sel dengan menggunakan variasi ( $P,R$ ) pada uRLBP yakni ( $P=8,R=1$ ), ( $P=8,R=2$ ), dan ( $P=8,R=3$ ) diperoleh rata-rata akurasi yakni 44.24%, 44.31%, dan 45.13% yang diklasifikasikan

menggunakan *Fuzzy k*-NN dengan parameter  $k=2$  sampai dengan  $k=14$ . Rata-rata akurasi klasifikasi dari tiga pengujian variasi  $(P,R)$  pada uRLBP memiliki akurasi yang tidak jauh berbeda. Dari tiga pengujian klasifikasi tersebut didapatkan akurasi optimal yakni 46.67%, 46.02%, dan 46.24%. Akurasi terbaik dari tiga pengujian tersebut didapatkan ketika nilai parameter  $(P=8,R=1)$  pada uRLBP dan  $k=13$  pada *Fuzzy k*-NN dengan akurasi klasifikasi mencapai 46.67%. Gambar 4.5 menunjukkan pengujian klasifikasi tujuh kelas sel citra *pap smear* menggunakan fitur tekstur uRLBP  $(P=8,R=1)$ .

Rendahnya akurasi pada klasifikasi tujuh kelas sel disebabkan karena pola fitur tekstur antara tujuh kelas sel memiliki kemiripan. Secara visual tekstur antar tujuh kelas memiliki karakter tekstur yang halus (*smooth texture*). Hal ini menjadikan pola fitur tekstur yang dihasilkan dari metode uRLBP memiliki kemiripan.

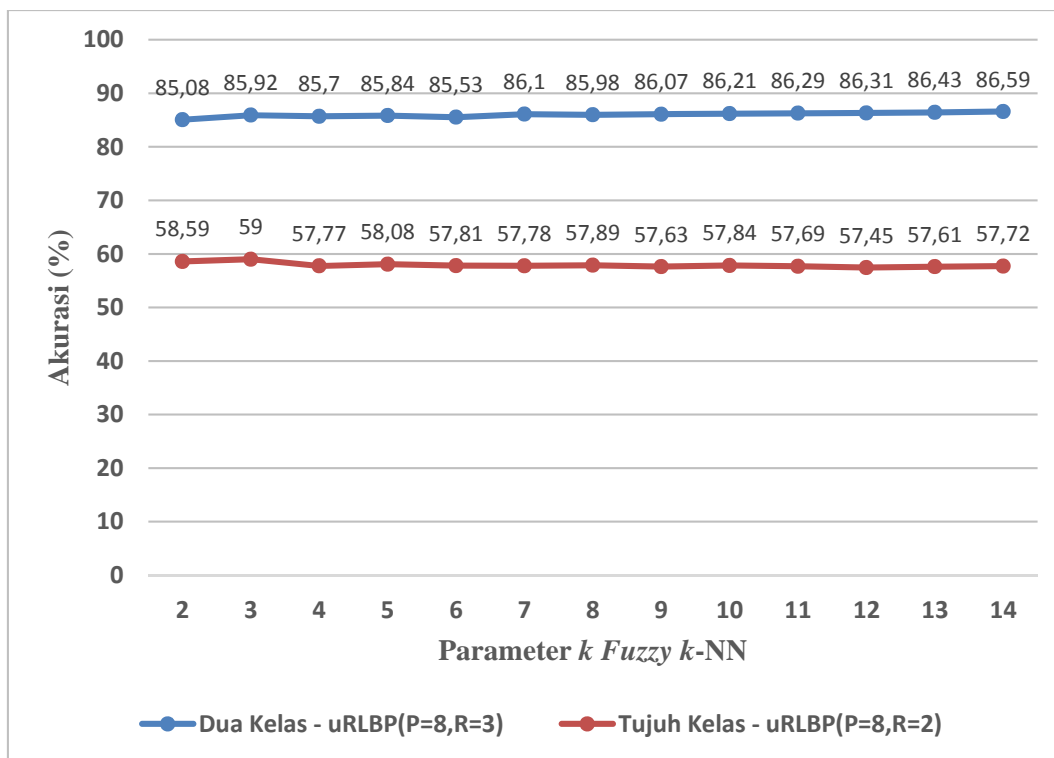
#### **4.4.2 Fitur Tekstur yang *Invariant* terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra *Pap Smear***

Bagian ini membahas hasil pengujian klasifikasi citra *pap smear* dengan hanya menggunakan fitur tekstur terhadap citra yang dirotasi beberapa arah. Pada proses pengujian klasifikasi dua kategori sel dengan menggunakan variasi  $(P,R)$  pada uRLBP yakni  $(P=8,R=1)$ ,  $(P=8,R=2)$ , dan  $(P=8,R=3)$  diperoleh rata-rata akurasi yakni 85.68%, 85.43%, dan 86.00% yang diklasifikasikan menggunakan *Fuzzy k*-NN dengan parameter  $k=2$  sampai dengan  $k=14$ . Rata-rata akurasi klasifikasi dari tiga pengujian variasi  $(P,R)$  pada uRLBP memiliki akurasi yang tidak jauh berbeda. Dari tiga pengujian klasifikasi tersebut didapatkan akurasi optimal yakni 86.38%, 85.96%, dan 86.59%. Akurasi terbaik dari tiga pengujian tersebut didapatkan ketika nilai parameter  $(P=8,R=3)$  pada uRLBP dan  $k=14$  pada *Fuzzy k*-NN dengan akurasi klasifikasi mencapai 86.59%.

. Pada proses pengujian klasifikasi tujuh kelas sel dengan menggunakan variasi  $(P,R)$  pada uRLBP yakni  $(P=8,R=1)$ ,  $(P=8,R=2)$ , dan  $(P=8,R=3)$  diperoleh rata-rata akurasi yakni 57.77%, 57.91%, dan 58.01% yang diklasifikasikan menggunakan *Fuzzy k*-NN dengan parameter  $k=2$  sampai dengan  $k=14$ . Rata-rata akurasi klasifikasi dari tiga pengujian variasi  $(P,R)$  pada uRLBP memiliki akurasi

yang tidak jauh berbeda. Dari tiga pengujian klasifikasi tersebut didapatkan akurasi optimal yakni 58.37%, 59.00%, dan 58.69%. Akurasi terbaik dari tiga pengujian tersebut didapatkan ketika nilai parameter ( $P=8,R=2$ ) pada uRLBP dan  $k=3$  pada *Fuzzy k*-NN dengan akurasi klasifikasi mencapai 59.00%. Gambar 4.6 menunjukkan pengujian klasifikasi dua kategori sel menggunakan fitur tekstur uRLBP ( $P=8,R=3$ ) dan klasifikasi tujuh kelas sel menggunakan fitur tekstur uRLBP ( $P=8,R=2$ ).

Rendahnya akurasi pada klasifikasi tujuh kelas sel disebabkan karena pola fitur tekstur antar tujuh kelas memiliki kemiripan. Secara visual tekstur antar tujuh kelas memiliki karakteristik yang mirip yakni tekstur nukleus yang halus untuk semua kelas. Hal ini menjadikan pola fitur tekstur yang dihasilkan dari metode uRLBP memiliki kemiripan.











Gambar 4.6 Akurasi klasifikasi berdasarkan Fitur Tekstur.





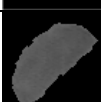
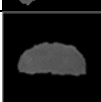


Tabel 4.25 dan tabel 4.26 merupakan hasil ekstraksi fitur menggunakan metode uRLBP dengan parameter ( $P=8,R=3$ ) dan parameter ( $P=8,R=2$ ). Nilai fitur

untuk parameter ( $P,R$ ) yang berbeda menghasilkan nilai fitur yang berbeda, hal ini disebabkan karena perbedaan radius pada metode uRLBP dalam mengambil nilai fitur tekstur. Nilai fitur yang dihasilkan oleh metode uRLBP dengan variasi parameter  $R$  yang berbeda mempunyai pola nilai fitur yang tidak jauh berbeda. Nilai fitur nomor satu pada urutan 59 fitur mempunyai nilai fitur yang sama ketika dirotasi pada arah kelipatan  $90^\circ$ , walaupun urutan fitur lainnya tidak selalu tepat sama namun mempunyai kemiripan. Pada citra yang dirotasi dengan arah bukan dengan kelipatan arah  $90^\circ$  terjadi perbedaan nilai fitur, yakni ketika diputar dengan arah  $45^\circ$ . Hal ini disebabkan dimensi fitur citra bertambah dari aslinya sehingga susunan tekstur dan hasil perhitungan fitur tekstur juga berubah. Hal ini mengakibatkan penurunan akurasi pada tujuh kelas sel bukan disebabkan fitur yang tidak *invariant* terhadap rotasi.

Tabel 4.25 Nilai fitur tekstur uRLBP ( $P=8,R=3$ ) citra kelas *carcinoma in situ* pada berbagai rotasi.

Data Masukan		Nama <i>File</i> Citra Asli	Fitur Hasil (1;2;3;4;5;6;..... 56;57;58;59)
Rotasi	Citra		
$0^\circ$		149143370- 149143378- 001.BMP	238;20;26;14;30;11; ..... 19;18;2349;661
$45^\circ$			184;15;38;9;35;15; ..... 14;11;7229;590
$90^\circ$			238;13;23;12;37;14; ..... 19;19;2349;657
$135^\circ$			184;14;41;8;31;12; ..... 14;10;7229;591
$180^\circ$			238;20;23;14;31;14; ..... 18;16;2349;659
$225^\circ$			184;15;38;7;35;14; ..... 14;11;7229;593
$270^\circ$			238;13;30;14;28;12; ..... 18;17;2349;662
$315^\circ$			184;19;41;9;28;13; ..... 14;10;7229;592

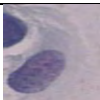
Tabel 4.26 Nilai fitur tekstur uRLBP ( $P=8,R=2$ ) citra kelas *carcinoma in situ* pada berbagai rotasi.

Data Masukan		Nama <i>File</i> Citra Asli	Fitur Hasil (1;2;3;4;5;6;..... 56;57;58;59)
Rotasi	Citra		
0°		149143370- 149143378- 001.BMP	200;16;41;11;27;10;..... 15;10;2663;612
45°			179;9;55;4;24;15; ..... 22;13;7645;502
90°			200;15;36;10;29;11; ..... 13;10;2664;611
135°			179;11;55;5;24;12; ..... 20;13;7645;503
180°			200;19;38;8;26;11; ..... 12;11;2664;611
225°			179;10;52;4;24;15; ..... 22;13;7646;502
270°			200;16;37;8;28;10; ..... 13;10;2663;611
315°			179;9;56;4;21;13; ..... 23;13;7646;502

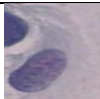
Tabel 4.27 menunjukkan nilai keanggotaan fitur tekstur menggunakan klasifikasi *Fuzzy k*-NN dengan parameter  $k=14$ . Citra data uji tersebut adalah kelas *carcinoma in situ* dengan nama *file* citra asli *pap smear* (149314881-149314903-001.BMP) diekstraksi menggunakan uRLBP ( $P=8,R=3$ ) yang label kelas aslinya merupakan kelas 2 dalam pembagian 2 kelas (kategori sel). Berdasarkan nilai keanggotaannya, jika diklasifikasikan berdasarkan 2 kelas maka prediksi kelasnya benar yakni kelas 2 (abnormal). Tabel 4.28 menunjukkan nilai keanggotaan fitur tekstur menggunakan klasifikasi *Fuzzy k*-NN dengan parameter  $k=3$ . Citra yang diujikan adalah kelas *carcinoma in situ* diekstraksi menggunakan uRLBP ( $P=8,R=2$ ) yang label kelas aslinya merupakan kelas 7 dalam pembagian 7 kelas. Berdasarkan nilai keanggotaannya, jika diklasifikasikan berdasarkan 7 kelas maka prediksi kelasnya salah karena nilai keanggotaan tertingginya pada kelas 4 (*mild dysplasia*).



Tabel 4.27 Contoh data uji fitur tekstur uRLBP ( $P=8,R=3$ ) dan hasil nilai keanggotaan dengan klasifikasi *Fuzzy k*-NN untuk dua kategori sel.


Data Uji	Rotasi	Kelas		Nilai keanggotaan pada setiap kelas	
		Asli	Prediksi	1	2
	135°	2	2	0.146	<b>0.854</b>

Tabel 4.28 Contoh data uji fitur tekstur uRLBP ( $P=8,R=2$ ) dan hasil nilai keanggotaan dengan klasifikasi *Fuzzy k*-NN untuk tujuh kelas sel.

Data Uji	Rotasi	Kelas		Nilai keanggotaan pada setiap kelas						
		Asli	Prediksi	1	2	3	4	5	6	7
	135°	7	4	0	0	0	<b>1</b>	0	0	0

#### 4.4.3 Fitur Bentuk yang *Invariant* terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra *Pap Smear*

Bagian ini membahas hasil pengujian klasifikasi citra *pap smear* dengan hanya menggunakan fitur bentuk terhadap citra yang dirotasi beberapa arah. Pada proses pengujian klasifikasi dua kategori sel citra *pap smear*, diperoleh rata-rata akurasi 99.80% yang diklasifikasikan menggunakan *Fuzzy k*-NN dengan parameter  $k=2$  sampai dengan  $k=14$ . Dari pengujian tersebut didapatkan akurasi optimal yakni 99.84% ketika nilai parameter  $k=2$  dan  $k=3$  pada *Fuzzy k*-NN. Pada proses pengujian klasifikasi tujuh kelas sel citra *pap smear*, diperoleh rata-rata akurasi 98.69% yang diklasifikasikan menggunakan *Fuzzy k*-NN dengan parameter  $k=2$  sampai dengan  $k=14$ . Dari pengujian tersebut didapatkan akurasi optimal yakni 98.74% ketika nilai parameter  $k=10$  dan  $k=11$  pada *Fuzzy k*-NN. Menurunnya akurasi pada klasifikasi tujuh kelas disebabkan karena beberapa fitur bentuk antar tujuh kelas memiliki kemiripan. Secara visual ada beberapa citra biner untuk ekstraksi fitur bentuk memiliki karakteristik yang mirip. Gambar 4.7 menunjukkan hasil akurasi klasifikasi menggunakan fitur bentuk untuk kategori dua kategori sel dan tujuh kelas sel.











Gambar 4.7 Akurasi klasifikasi berdasarkan Fitur Bentuk.









Tingginya akurasi hasil klasifikasi fitur bentuk deskriptor regional area dan *compactness* untuk kategori dua kategori sel dan tujuh kelas sel dikarenakan tidak adanya *noise* pada citra biner nukleus dan citra biner sel. *Noise* pada citra biner dihilangkan dengan menggunakan operasi morfologi *opening* pada saat praproses. Sehingga kombinasi 4 fitur bentuk antara lain area nukleus, *compactness* nukleus, area sel, dan *compactness* sel dapat menghasilkan fitur yang *invariant* terhadap rotasi dengan akurasi yang tinggi.

Tabel 4.29 dan tabel 4.30 merupakan hasil ekstraksi fitur area dan *compactness* pada citra biner. Fitur bentuk mampu menghasilkan fitur yang sama ketika dirotasi pada arah kelipatan  $90^\circ$ . Pada citra yang dirotasi dengan arah bukan dengan kelipatan arah  $90^\circ$  terjadi perbedaan nilai fitur, hal tersebut tidak terlalu signifikan. Perubahan nilai fitur terjadi ketika perputaran  $45^\circ$ . Meskipun perubahan secara visual tidak nampak ketika citra diputar beberapa arah akan tetapi fitur area adalah perhitungan jumlah piksel pada objek sehingga sedikit terjadi perubahan piksel. Fitur *compactness* juga mempunyai kesamaan pola nilai fitur dengan fitur area, hal ini terjadi karena perhitungan *compactness* memerlukan perhitungan area untuk mendapatkan nilai fitur.


Tabel 4.29 Nilai fitur bentuk nukleus citra kelas *normal squamous* pada berbagai rotasi.

Data Masukan		Nama <i>File</i> Citra Asli	Nilai Fitur Bentuk Nukleus	
Rotasi	Citra		Area	<i>Compactness</i>
0°		153958345- 153958392- 001.BMP	794	13.772
45°			796	14.294
90°			794	13.772
135°			796	14.294
180°			794	13.772
225°			796	14.294
270°			794	13.772
315°			796	14.294


Tabel 4.30 Nilai fitur bentuk sel citra kelas *normal squamous* pada berbagai rotasi

Data Masukan		Nama <i>File</i> Citra Asli	Nilai Fitur Bentuk Sel	
Rotasi	Citra		Area	<i>Compactness</i>
0°		153958345- 153958392- 001.BMP	28881	17.349
45°			28869	17.880
90°			28881	17.349
135°			28869	17.880
180°			28881	17.349
225°			28869	17.880
270°			28881	17.349
315°			28869	17.880

Tabel 4.31 Contoh data uji fitur bentuk dan hasil nilai keanggotaan dengan klasifikasi *Fuzzy k*-NN untuk dua kategori sel.

Data Uji	Rotasi	Kelas		Nilai keanggotaan pada setiap kelas	
		Asli	Prediksi	1	2
	270°	1	1	<b>1</b>	0

Tabel 4.32 Contoh data uji fitur bentuk dan hasil nilai keanggotaan dengan klasifikasi *Fuzzy k*-NN untuk tujuh kelas sel.

Data Uji	Rotasi	Kelas		Nilai keanggotaan pada setiap kelas						
		Asli	Prediksi	1	2	3	4	5	6	7
	270°	1	2	0.033	<b>0.967</b>	0	0	0	0	0

Tabel 4.31 menunjukkan nilai keanggotaan fitur bentuk menggunakan klasifikasi *Fuzzy k*-NN dengan parameter  $k=2$ . Citra data uji tersebut adalah kelas *normal squamous* dengan nama *file* citra asli (157185208-157185238-001.BMP) yang label kelas aslinya merupakan kelas 1 dalam pembagian 2 kelas (kategori sel). Berdasarkan nilai keanggotaannya, jika diklasifikasikan berdasarkan 2 kelas maka prediksi kelasnya benar yakni kelas 1 (normal). Tabel 4.32 menunjukkan nilai keanggotaan fitur bentuk menggunakan klasifikasi *Fuzzy k*-NN dengan parameter  $k=10$ . Citra yang diujikan adalah kelas *normal squamous* yang label kelas aslinya merupakan kelas 1 dalam pembagian 7 kelas. Berdasarkan nilai keanggotaannya, jika diklasifikasikan berdasarkan 7 kelas maka prediksi kelasnya salah karena nilai keanggotaan tertingginya pada kelas 2 (*intermediate squamouse*).

#### 4.4.4 Kombinasi Fitur Bentuk dan Fitur Tekstur yang *Invariant* terhadap Rotasi untuk Klasifikasi Sel Serviks pada Citra *Pap Smear*


Pada hasil uji coba pengaruh kombinasi fitur bentuk dan fitur tekstur pada klasifikasi dua kategori sel citra *pap smear*. Pada proses pengujian klasifikasi untuk dua kategori sel pada kombinasi fitur bentuk dan fitur tekstur, dengan variasi ( $P,R$ ) pada uRLBP yakni ( $P=8,R=1$ ), ( $P=8,R=2$ ), dan ( $P=8,R=3$ ) diperoleh rata-rata akurasi yakni 89.42%, 89.37%, dan 89.40% yang diklasifikasikan menggunakan *Fuzzy k*-NN dengan parameter  $k=2$  sampai dengan  $k=14$ . Rata-rata akurasi

klasifikasi kombinasi fitur dari tiga pengujian antara kombinasi fitur bentuk dan fitur tekstur dengan variasi  $(P,R)$  pada uRLBP memiliki akurasi yang tidak jauh berbeda. Dari tiga pengujian kombinasi fitur bentuk dan fitur tekstur seperti yang ditunjukkan pada tabel 4.15, tabel 4.16, dan tabel 4.17, didapatkan akurasi optimal kombinasi fitur bentuk dan fitur tekstur uRLBP  $(P=8,R=1)$  mencapai 91.53%, kombinasi fitur bentuk dan fitur tekstur uRLBP  $(P=8,R=2)$  mencapai 91.53%, dan kombinasi fitur bentuk dan fitur tekstur uRLBP  $(P=8,R=3)$  mencapai 91.59%. Akurasi terbaik dari tiga pengujian kombinasi fitur tersebut didapatkan ketika nilai parameter  $(P=8,R=3)$  pada uRLBP dan  $k=14$  pada *Fuzzy k*-NN dengan akurasi klasifikasi kombinasi fitur mencapai 91.59%.

Tabel 4.33 menunjukkan bahwa kombinasi fitur bentuk dan fitur tekstur mengalami peningkatan akurasi. Perbandingan akurasi kombinasi fitur yang diusulkan mengalami penurunan jika dibandingkan dengan akurasi klasifikasi hanya dengan fitur bentuk dan mengalami peningkatan jika dibandingkan dengan akurasi klasifikasi hanya dengan fitur tekstur. Fitur tekstur yang digunakan untuk kombinasi adalah fitur tekstur ketika dikombinasikan dengan fitur bentuk menghasilkan akurasi terbaik dari variasi parameter  $(P,R)$ . Dari ketiga variasi  $(P,R)$  pada uRLBP yang dikombinasikan dengan fitur bentuk, parameter  $(P=8,R=3)$  menghasilkan akurasi klasifikasi tertinggi pada kombinasi fitur dibandingkan dengan fitur bentuk yang dikombinasikan dengan fitur tekstur dengan variasi  $(P,R)$  lainnya yakni  $(P=8,R=1)$  dan  $(P=8,R=2)$  pada uRLBP. Dengan meningkatnya nilai parameter  $k$  pada *Fuzzy k*-NN yang diujikan pada kombinasi fitur bentuk dan fitur tekstur, akurasi klasifikasi mengalami peningkatan dengan rata-rata akurasi 89.40% dan akurasi kombinasi fitur mencapai 91.59%. Dilihat hanya pada akurasi fitur bentuk atau fitur tekstur untuk dua kategori sel, akurasi klasifikasi untuk fitur bentuk mengalami penurunan ketika nilai parameter  $k$  pada *Fuzzy k*-NN mengalami peningkatan dengan perbedaan akurasi yang tidak terlalu signifikan. Akurasi klasifikasi hanya pada fitur tekstur uRLBP  $(P=8,R=3)$  mengalami peningkatan ketika nilai parameter  $k$  pada *Fuzzy k*-NN dengan perbedaan peningkatan akurasi yang tidak terlalu signifikan.

Tabel 4.33 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur.

$k$ Fuzzy $k$ -NN	Akurasi (%)		
	Bentuk	Tekstur	Kombinasi
		uRLBP( $P=8,R=3$ )	Bentuk + uRLBP( $P=8,R=3$ )
2	<b>99.84</b>	85.08	85.48
3	<b>99.84</b>	85.92	88.22
4	99.83	85.70	88.66
5	99.83	85.84	88.53
6	99.80	85.53	88.28
7	99.81	86.10	88.78
8	99.81	85.98	89.70
9	99.81	86.07	89.90
10	99.80	86.21	90.15
11	99.78	86.29	90.53
12	99.77	86.31	91.03
13	99.77	86.43	91.40
14	99.77	<b>86.59</b>	<b>91.59</b>



Gambar 4.8 Hasil akurasi klasifikasi dua kategori sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur.


Pada hasil uji coba pengaruh kombinasi fitur bentuk dan fitur tekstur pada klasifikasi tujuh kelas sel citra *pap smear*. Pada proses pengujian klasifikasi untuk tujuh kelas sel pada kombinasi fitur bentuk dan fitur tekstur, dengan variasi ( $P,R$ ) pada uRLBP yakni ( $P=8,R=1$ ), ( $P=8,R=2$ ), dan ( $P=8,R=3$ ) diperoleh rata-rata

akurasi yakni 66.96%, 66.95%, dan 67.06% yang diklasifikasikan menggunakan *Fuzzy k*-NN dengan parameter  $k=2$  sampai dengan  $k=14$ . Rata-rata akurasi klasifikasi kombinasi fitur dari tiga pengujian antara kombinasi fitur bentuk dan fitur tekstur dengan variasi  $(P,R)$  pada uRLBP memiliki akurasi yang tidak jauh berbeda. Dari tiga pengujian kombinasi fitur bentuk dan fitur tekstur seperti yang ditunjukkan pada tabel 4.18, tabel 4.19, dan tabel 4.20, didapatkan akurasi optimal kombinasi fitur bentuk dan fitur tekstur uRLBP  $(P=8,R=1)$  mencapai 67.72%, kombinasi fitur bentuk dan fitur tekstur uRLBP  $(P=8,R=2)$  mencapai 67.60%, dan kombinasi fitur bentuk dan fitur tekstur uRLBP  $(P=8,R=3)$  mencapai 67.89%. Akurasi terbaik dari tiga pengujian kombinasi fitur tersebut didapatkan ketika nilai parameter  $(P=8,R=3)$  pada uRLBP dan  $k=14$  pada *Fuzzy k*-NN dengan akurasi klasifikasi kombinasi fitur mencapai 67.89%.

Tabel 4.34 menunjukkan bahwa kombinasi fitur bentuk dan fitur tekstur mengalami peningkatan akurasi. Perbandingan akurasi kombinasi fitur yang diusulkan mengalami penurunan jika dibandingkan dengan akurasi klasifikasi hanya dengan fitur bentuk dan mengalami peningkatan jika dibandingkan dengan akurasi klasifikasi hanya dengan fitur tekstur. Fitur tekstur yang digunakan untuk kombinasi adalah fitur tekstur ketika dikombinasikan dengan fitur bentuk menghasilkan akurasi terbaik dari variasi parameter  $(P,R)$ . Dari ketiga variasi  $(P,R)$  pada uRLBP yang dikombinasikan dengan fitur bentuk, parameter  $(P=8,R=3)$  menghasilkan akurasi klasifikasi tertinggi pada kombinasi fitur dibandingkan dengan fitur bentuk yang dikombinasikan dengan fitur tekstur dengan variasi  $(P,R)$  lainnya yakni  $(P=8,R=1)$  dan  $(P=8,R=2)$  pada uRLBP. Dengan meningkatnya nilai parameter  $k$  pada *Fuzzy k*-NN yang diujikan pada kombinasi fitur bentuk dan fitur tekstur, akurasi klasifikasi mengalami peningkatan dengan rata-rata akurasi 67.06% dan akurasi kombinasi fitur mencapai 67.89%. Dilihat hanya pada akurasi fitur bentuk atau fitur tekstur untuk tujuh kelas sel, akurasi klasifikasi untuk fitur bentuk mengalami peningkatan ketika nilai parameter  $k$  pada *Fuzzy k*-NN dengan perbedaan peningkatan akurasi yang tidak terlalu signifikan. Akurasi klasifikasi hanya pada fitur tekstur uRLBP  $(P=8,R=3)$  mengalami penurunan ketika nilai parameter  $k$  pada *Fuzzy k*-NN dengan perbedaan peningkatan akurasi yang tidak terlalu signifikan.

Tabel 4.34 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur.

$k$ Fuzzy $k$ -NN	Akurasi (%)		
	Bentuk	Tekstur	Kombinasi
		uRLBP( $P=8,R=3$ )	Bentuk + uRLBP( $P=8,R=3$ )
2	98.66	<b>58.69</b>	64.98
3	98.66	58.45	65.66
4	98.66	57.98	66.54
5	98.68	58.25	67.53
6	98.66	57.92	67.16
7	98.68	57.89	67.66
8	98.71	57.91	67.33
9	98.72	57.78	67.77
10	<b>98.74</b>	57.94	67.33
11	<b>98.74</b>	58.17	67.33
12	98.71	57.80	67.46
13	98.71	57.73	67.11
14	98.68	57.67	<b>67.89</b>



Gambar 4.9 Hasil akurasi klasifikasi tujuh kelas sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur.

Berdasarkan pengujian yang dilakukan seperti yang ditunjukkan pada gambar 4.8 dan gambar 4.9 bahwa akurasi dua kategori sel dan akurasi tujuh kelas sel antara fitur bentuk dan fitur tekstur pada setiap pengujian parameter  $k$  pada



*Fuzzy k*-NN dari  $k=2$  sampai dengan  $k=14$  memiliki perbedaan yang kecil. Dari pengujian tersebut didapatkan kesimpulan bahwa akurasi klasifikasi kombinasi fitur untuk dua kategori sel mencapai 91.59% dan kurasi klasifikasi kombinasi fitur pada tujuh kelas sel mencapai 67.89% ketika nilai parameter ( $P=8,R=3$ ) pada uRLBP dan  $k=14$  pada *Fuzzy k*-NN.


Rendahnya akurasi pada klasifikasi kombinasi fitur untuk tujuh kelas sel disebabkan karena pola fitur tekstur antar tujuh kelas memiliki kemiripan. Secara visual tekstur antar tujuh kelas memiliki karakteristik yang mirip yakni tekstur nukleus yang halus untuk semua kelas. Hal ini menjadikan pola fitur tekstur yang dihasilkan dari metode uRLBP memiliki kemiripan.

#### **4.4.5 Perbandingan dengan Metode Sebelumnya**


Kombinasi fitur bentuk dan fitur tekstur sebelumnya yang telah digunakan dalam mengklasifikasikan sel serviks pada citra *pap smear* dengan tidak memperhatikan adanya fitur *invariant* terhadap rotasi pada ekstraksi fitur tekstur adalah perhitungan nilai Homogenitas dengan perhitungan *Gray Level Co-Occurrence Matrix* (GLCM) (Chankong, 2014) dan yang memiliki kemampuan ekstraksi fitur tekstur yang *invariant* terhadap rotasi adalah metode *Uniform Rotation Invariant Local Binary Pattern* ( $LBP^{riu}$ ) (Plissiti, 2011), *Local Binary Pattern Histogram Fourier* (LBP-HF)(Pasrun, 2016).

Pengujian pada uji coba sebelumnya terhadap kombinasi fitur bentuk dan fitur tekstur yang diusulkan dengan menghasilkan akurasi klasifikasi tertinggi digunakan untuk perbandingan metode dengan metode sebelumnya. Hasil uji coba metode yang diusulkan memiliki akurasi tertinggi pada kombinasi fitur bentuk dan fitur tekstur mencapai 91.59% untuk dua kategori sel dan 67.89% untuk tujuh kelas sel ketika parameter ( $P=8,R=3$ ) pada uRLBP dan parameter  $k=14$  pada *Fuzzy k*-NN. Nilai parameter ( $P,R$ ) pada uRLBP dan nilai parameter  $k$  pada *Fuzzy k*-NN yang digunakan disesuaikan dengan akurasi tertinggi yang diperoleh pada uji coba kombinasi fitur bentuk dan fitur tekstur pada uji coba sebelumnya. Pengujian menunjukkan hasil akurasi kombinasi fitur yang diusulkan dengan kombinasi fitur lain untuk mengetahui keefektifan metode dalam menghasilkan fitur yang *invariant* terhadap rotasi. Gambar 4.10 dan gambar 4.11 menunjukkan perbandingan akurasi

metode yang diusulkan dengan metode sebelumnya untuk kategori dua kategori sel dan tujuh kelas sel.



Gambar 4.10 Perbandingan akurasi metode untuk dua kategori sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur dengan metode sebelumnya.




Gambar 4.11 Perbandingan akurasi metode untuk tujuh kelas sel berdasarkan fitur bentuk, fitur tekstur, dan kombinasi fitur dengan metode sebelumnya.

Pada klasifikasi dua kategori sel seperti yang ditunjukkan pada gambar 4.10. Akurasi kombinasi fitur yang diusulkan lebih tinggi dibandingkan dengan kombinasi fitur metode sebelumnya. Akurasi klasifikasi kombinasi fitur pada semua metode lebih rendah dibandingkan dengan akurasi hanya pada fitur bentuk. Tabel 4.35 dan gambar 4.12 menunjukkan penurunan akurasi pada kombinasi fitur dibandingkan akurasi hanya pada fitur bentuk. Penurunan akurasi metode yang diusulkan lebih rendah 8.18% dibandingkan dengan dengan akurasi fitur bentuk. Sedangkan penurunan tiga metode sebelumnya lebih dari 8.18%. Penurunan akurasi yang lebih rendah menunjukkan bahwa metode yang diusulkan lebih baik dibandingkan dengan tiga metode sebelumnya.

Tabel 4.35 Perbandingan akurasi kombinasi fitur dengan akurasi fitur bentuk untuk dua kategori sel.


Fitur	Akurasi (%)		
	Bentuk	Kombinasi	Penurunan
Bentuk + Tekstur Homogenitas GLCM	100.00	85.87	14.13
Bentuk + Tekstur LBP <sup>riu</sup> ( $P=8, R=3$ )	99.77	91.40	8.37
Bentuk + Tekstur LBP-HF ( $P=8, R=3$ )	99.77	85.28	14.49
Bentuk + Tekstur uRLBP ( $P=8, R=3$ )	99.77	91.59	8.18



Gambar 4.12 Penurunan akurasi kombinasi fitur dibandingkan akurasi dengan hanya fitur bentuk untuk dua kategori sel.

Tabel 4.36 Perbandingan akurasi kombinasi fitur dengan akurasi fitur bentuk untuk tujuh kelas sel.

Fitur	Akurasi (%)		
	Bentuk	Kombinasi	Penurunan
Bentuk + Tekstur Homogenitas GLCM	99.78	46.56	53.22
Bentuk + Tekstur LBP <sup>priu</sup> ( $P=8, R=3$ )	98.68	66.94	31.74
Bentuk + Tekstur LBP-HF ( $P=8, R=3$ )	98.68	65.88	32.80
Bentuk + Tekstur uRLBP ( $P=8, R=3$ )	98.68	67.89	30.79



Gambar 4.13 Penurunan akurasi kombinasi fitur dibandingkan akurasi dengan hanya fitur bentuk untuk tujuh kelas sel.


Pada klasifikasi tujuh kelas seperti yang ditunjukkan pada gambar 4.11. Akurasi kombinasi fitur yang diusulkan lebih tinggi dibandingkan dengan kombinasi fitur metode sebelumnya. Akurasi klasifikasi kombinasi fitur pada semua metode lebih rendah dibandingkan dengan akurasi hanya pada fitur bentuk. Tabel 4.36 dan gambar 4.13 menunjukkan penurunan akurasi pada kombinasi fitur dibandingkan akurasi hanya pada fitur bentuk. Penurunan akurasi metode yang diusulkan lebih rendah 30.79% dibandingkan dengan dengan akurasi fitur bentuk. Sedangkan penurunan tiga metode sebelumnya lebih dari 30.79%. Penurunan akurasi yang lebih rendah menunjukkan bahwa metode yang diusulkan lebih baik dibandingkan dengan tiga metode sebelumnya.

Pada pengujian dua kategori sel dan tujuh kelas sel yang ditunjukkan pada gambar 4.10 dan gambar 4.11, akurasi klasifikasi pada kombinasi fitur lebih tinggi dibandingkan hanya dengan akurasi fitur tekstur. Dari gambar 4.10 menunjukkan bahwa pada metode kombinasi fitur lain yang akurasinya mengalami penurunan dibandingkan dengan akurasi hanya dengan fitur bentuk dan fitur tekstur yakni kombinasi fitur bentuk dan fitur tekstur LBP-HF. Hal ini menunjukkan bahwa kombinasi tersebut kurang cocok dalam menghasilkan fitur yang *invariant* terhadap rotasi untuk klasifikasi dua kategori sel.


Ditinjau dari fitur bentuk atau fitur tekstur saja. Akurasi fitur bentuk yang diusulkan lebih rendah dibandingkan dengan fitur bentuk yang diusulkan oleh (Chankong, 2014). Penurunan tersebut disebabkan oleh pengurangan jumlah fitur bentuk, namun penurunan tersebut tidak signifikan yakni 0.23% untuk dua kategori sel dan 1.1% untuk tujuh kelas sel. Akurasi fitur tekstur yang diusulkan lebih tinggi dari Homogenitas GLCM dan LBP<sup>riu</sup> namun lebih rendah dari LBP-HF untuk kategori dua kategori sel. Sedangkan untuk kategori tujuh kelas sel, akurasi fitur tekstur yang diusulkan lebih tinggi dibandingkan akurasi fitur tekstur sebelumnya.

Tabel 4.37 menunjukkan contoh nilai keanggotaan klasifikasi *Fuzzy k*-NN untuk kombinasi fitur yang diusulkan dan tabel 4.38 menunjukkan contoh nilai keanggotaan klasifikasi *Fuzzy k*-NN untuk kombinasi fitur yang tidak *invariant* terhadap rotasi. Dari tabel 4.37 dan tabel 4.38 terbukti bahwa kombinasi fitur yang diusulkan dapat mengurangi kesalahan klasifikasi yang disebabkan oleh perbedaan fitur data uji karena adanya rotasi citra.

Tabel 4.37 Contoh nilai keanggotaan klasifikasi dua kategori sel kombinasi fitur bentuk dan fitur tekstur uRLBP.

Data Uji	Rotasi	Nama <i>File</i> citra asli	Kelas		Nilai Keanggotaan <i>Fuzzy k</i> -NN		Panjang Fitur
			Asli	Prediksi	1	2	
	225°	153958345-153958392-001.BMP	1	1	0.527	0.473	63

Tabel 4.38 Contoh nilai keanggotaan klasifikasi dua kategori sel kombinasi fitur bentuk dan fitur tekstur Homogenitas GLCM.

Data Uji	Rotasi	Nama <i>File</i> citra asli	Kelas		Nilai Keanggotaan <i>Fuzzy k</i> -NN		Panjang Fitur
			Asli	Prediksi	1	2	
	225°	153958345-153958392-001.BMP	1	2	0.225	0.775	9

Tabel 4.37 menunjukkan nilai keanggotaan kombinasi fitur bentuk dan fitur tekstur yang diusulkan dengan parameter ( $P=8, R=3$ ) pada uRLBP menggunakan klasifikasi *Fuzzy k*-NN dengan parameter  $k=14$ . Citra data uji tersebut adalah kelas *normal squamous* yang label kelas aslinya merupakan kelas 1 dalam pembagian 2 kelas (kategori sel). Berdasarkan nilai keanggotaannya, jika diklasifikasikan berdasarkan 2 kelas maka prediksi kelasnya benar yakni kelas 1 (normal). Tabel 4.38 menunjukkan nilai keanggotaan kombinasi fitur bentuk dan fitur tekstur Homogenitas GLCM (Chankong, 2014) menggunakan klasifikasi *Fuzzy k*-NN dengan parameter  $k=14$ . Citra yang diujikan adalah kelas *normal squamous* yang label kelas aslinya merupakan kelas 1 dalam pembagian 2 kelas. Berdasarkan nilai keanggotaannya, jika diklasifikasikan berdasarkan 2 kelas maka prediksi kelasnya salah karena nilai keanggotaan tertingginya pada kelas 2 (abnormal).

## **BAB 5**

### **KESIMPULAN DAN SARAN**

Pada bab ini menjelaskan mengenai kesimpulan yang diperoleh setelah melakukan serangkaian uji coba serta saran untuk pengembangan penelitian lebih lanjut.

#### **5.2 Kesimpulan**

Pada sub-bab ini dipaparkan kesimpulan yang dapat diambil berdasarkan hasil percobaan dan analisis penelitian yang dilakukan terhadap kombinasi fitur yang diusulkan. Kesimpulan tersebut sebagai berikut :

1. Kombinasi fitur bentuk dan fitur tekstur dapat menghasilkan fitur yang *invariant* terhadap rotasi dan digunakan untuk klasifikasi citra *pap smear* berdasarkan dua kategori sel dengan akurasi 91.59% ketika nilai parameter ( $P=8, R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k*-NN. Akurasi ini mengalami penurunan sebesar 8.18% dibandingkan dengan akurasi fitur bentuk dan mengalami peningkatan sebesar 5.00% dibandingkan dengan akurasi fitur tekstur.
2. Kombinasi fitur bentuk dan fitur tekstur dapat menghasilkan fitur yang *invariant* terhadap rotasi dan digunakan untuk klasifikasi citra *pap smear* berdasarkan tujuh kelas sel dengan akurasi 67.89% ketika nilai parameter ( $P=8, R=3$ ) pada uRLBP dan nilai parameter  $k=14$  pada *Fuzzy k*-NN. Akurasi ini mengalami penurunan sebesar 30.79% dibandingkan dengan akurasi fitur bentuk dan mengalami peningkatan sebesar 10.22% dibandingkan dengan akurasi fitur tekstur.
3. Kombinasi fitur yang diusulkan untuk dua kategori sel mengalami peningkatan akurasi sebesar 5.72% dibandingkan dengan kombinasi fitur bentuk dan fitur tekstur Homogenitas GLCM, 0.19% dibandingkan dengan kombinasi fitur bentuk dan fitur tekstur LBP<sup>riu</sup>, dan 6.31% dibandingkan dengan kombinasi fitur bentuk dan fitur tekstur LBP-HF.

4. Kombinasi fitur yang diusulkan untuk tujuh kelas sel mengalami peningkatan akurasi sebesar 21.33% dibandingkan dengan kombinasi fitur bentuk dan fitur tekstur Homogenitas GLCM, 0.95% dibandingkan dengan kombinasi fitur bentuk dan fitur tekstur LBP<sup>riu</sup>, dan 2.01% dibandingkan dengan kombinasi fitur bentuk dan fitur tekstur LBP-HF.
5. Penurunan akurasi kombinasi fitur untuk dua kategori sel yang diusulkan dibandingkan dengan hanya akurasi fitur bentuk, lebih rendah dibandingkan dengan akurasi kombinasi fitur lain dibandingkan dengan akurasi fitur bentuk. Penurunan akurasi tersebut adalah 8.18% untuk metode kombinasi fitur yang diusulkan, 14.13% kombinasi bentuk dan Homogenitas GLCM, 8.37% kombinasi bentuk dan LBP<sup>riu</sup>, dan 14.49% kombinasi bentuk dan LBP-HF. Penurunan akurasi yang lebih rendah menunjukkan bahwa metode yang diusulkan lebih optimal dibandingkan dengan metode sebelumnya.
6. Penurunan akurasi kombinasi fitur untuk tujuh kelas sel yang diusulkan dibandingkan dengan hanya akurasi fitur bentuk, lebih rendah dibandingkan dengan akurasi kombinasi fitur lain dibandingkan dengan akurasi fitur bentuk. Penurunan akurasi tersebut adalah 30.79% untuk metode kombinasi fitur yang diusulkan, 53.22% kombinasi bentuk dan Homogenitas GLCM, 31.74% kombinasi bentuk dan LBP<sup>riu</sup>, dan 32.80% kombinasi bentuk dan LBP-HF. Penurunan akurasi yang lebih rendah menunjukkan bahwa metode yang diusulkan lebih optimal dibandingkan dengan metode sebelumnya.
7. Nilai parameter  $(P,R)$  pada uRLBP yang menghasilkan akurasi klasifikasi tekstur terbaik yang diujikan pada citra acuan untuk dua kategori sel dan tujuh kelas sel, tidak dapat digunakan sebagai acuan untuk pemberian nilai parameter yang menghasilkan akurasi terbaik pada klasifikasi tekstur citra yang dirotasi beberapa arah dan pada klasifikasi kombinasi fitur bentuk dan fitur tekstur untuk dua kategori sel dan tujuh kelas sel.
8. Nilai parameter  $(P,R)$  pada uRLBP yang menghasilkan akurasi klasifikasi tekstur terbaik yang diujikan pada citra yang dirotasi beberapa arah untuk dua kategori sel dan tujuh kelas sel, tidak dapat digunakan sebagai acuan untuk pemberian nilai parameter yang menghasilkan akurasi terbaik pada klasifikasi



tekstur citra pada kombinasi fitur bentuk dan fitur tekstur untuk dua kategori sel dan tujuh kelas sel.

## **5.2 Saran**

Berdasarkan hasil yang didapatkan dari penelitian ini, saran yang dapat digunakan untuk penelitian-penelitian mendatang, yaitu penambahan fitur tekstur yang dapat membedakan dan meningkatkan akurasi klasifikasi terutama untuk tujuh kelas sel, seperti penambahan *input* citra hasil praproses yang menghasilkan citra *grayscale* sel untuk proses ekstraksi fitur tekstur.

**[Halaman ini sengaja dikosongkan]**

## DAFTAR PUSTAKA

- Jemal, A., Bray, F., Center, M.M., Ward, E., dan Forman, D. (2011). Global cancer statistics. *CA: A Cancer Journal for Clinicians*, 61(2), pp. 69-90.
- Njoroge, E., Alty, S. R., Gani, M.R., dan Alkatib, M. (2006). Classification of Cervical Cancer Cells Using FTIR Data. In *Engineering in Medicine and Biology Society, 2006, EMBS'06, 28th Annual International Conference of the IEEE* (pp. 5538-5341). IEEE.
- Kashyap, D., Somani, A., Shekhar, J., Bhan, A., Dutta, M. K., Burget, R., dan Riha, K. (2016). Cervical cancer detection and classification using Independent Level sets and multi SVMs. In *Telecommunications and Signal Processing (TSP), 2016 39th International Conference on* (pp. 523-528). IEEE.
- Haralick, R.M. (1979). Statistical and structural approaches to texture. In *Proceeding of the IEEE*. 67(5), pp. 786-804.
- Yusoff, I. A., Isa, N. A. M., Othman, N. H., Sulaiman, S.N., dan Jusman, Y. (2010). Performance of Neural Network Architectures: Cascade MLP Versus Extreme Learning Machine on Cervical Cell Image Classification. In *Information Sciences Signal Processing and their Applications (ISSPA), 2010 10th International Conference on* (pp. 308-311). IEEE.
- Rodenacker, K., dan Bengtsson, E. (2003). A Feature Set for Cytometry in Digitized Microscopic Images, *Analytical Cellular Pathology*, 25(1), pp. 1-36.
- Jantzen, J., dan Dounias, G. (2006). Analysis of Pap-Smear Image Data. In *Nature-Inspired Smart Information Systems 2nd Annual Symposium*.
- Chankong, T., Theera-Umpon, N., dan Auephanwiriyaikul, S. (2014). Automatic Cervical Cell Segmentation and Classification in Pap Smears. *Computer methods and programs in biomedicine*, 113(2), pp. 539-556.
- Jahne, B. (1997). *Digital image processing: Concepts, Algorithms, and Scientific Applications*. Berlin, Heidelberg: Springer-Verlag.

- Plissiti, M. E., Nikou, C., dan Charchanti, A. (2011). Combining Shape, Texture and Intensity Features for Cell Nuclei Extraction in Pap Smear Images. *Pattern Recognition Letters*, 32(6), pp. 838-853.
- Ojala, T., Pietikainen, M., dan Maenpaa, T. (2002). Multiresolution Gray-Scale and Rotation Invariant Texture Classification With Local Binary Patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(7), pp. 971-987.
- Nanni, L., Lumini, A., dan Brahnam, S. (2010). Local Binary Patterns Variants As Texture Descriptors for Medical Image Analysis. *Artificial intelligence in medicine*, 49(2), pp. 117-125.
- Rao, C. N., Sastry, S. S., Mallika, K., Tiong, H. S., dan Mahalakshmi, K. B. (2013). Co-Occurrence Matrix and Its Statistical Features as an Approach for Identification of Phase Transitions of Mesogens. *International Journal of Innovative Research in Science, Engineering and Technology*, 2(9), pp. 4531-4538.
- Sadhria, K. S., dan Andurkar, A. G. (2015). Review Paper on Different Co-Occurrence Matrices for Texture in CBIR. *International Journal of Advance Engineering and Research Development*, 2(6), pp. 650-654.
- Wang, S., Zhang, Y., Zhan, T., Phillips P., Zhang, Y., Liu, G., Lu, S., dan Wu, X. (2016). Pathological Brain Detection by Artificial Intelligence in Magnetic Resonance Imaging Scanning. *Progress In Electromagnetics Research*, 156, pp. 105-133.
- Pasrun, Y. P., Fatichah, C., dan Suciati, N. (2016). Penggabungan Fitur Bentuk dan Fitur Tekstur yang *Invariant* terhadap Rotasi untuk Klasifikasi citra *Pap Smear*. *Jurnal Buana Informatika*, 7(1). pp. 11-20.
- Prasetyo, E. (2012). *Data Mining Konsep Dan Aplikasi Menggunakan Matlab*. ANDI, Yogyakarta.
- Prasetyo, E.(2014). *Data Mining Mengolah Data Menjadi Informasi*. ANDI, Yogyakarta.
- Mehta, R., dan Egiazarian, K. (2013). Rotated Local Binary Pattern (RLBP) : Rotation invariant texture descriptor. In *Proceedings of International Conference on Pattern Recognition Applications and Methods*.

- Mehta, R., dan Egiazarian, K. (2016). Dominant Rotated Local Binary Pattern (DRLBP) for texture classification. *Pattern Recognition Letters*, 71, pp. 16-22.
- Rahmawati, R., Magdalena, R., dan Ramatryana, N. A. (2016). Perbandingan dan Analisis *k*-Nearest Neighbor dan Linear Discriminant Analysis untuk klasifikasi genre musik. *e-Proceeding of Engineering*, 3(2), pp. 1831-1837.
- Guo, Z., Zhang, L., dan Zhang, D. (2010). Rotation Invariant Texture Classification using LBP Variance (LBPV) with Global Matching. *Pattern Recognition*, 43(3), pp. 706-719.
- Ahonen, T., Matas, J., He, C., dan Pietikainen, M. (2009). Rotation invariant image description with local binary pattern histogram fourier features. In *Image Analysis* (pp. 61-70). Springer Berlin Heidelberg.
- Kadir, A., dan Susanto, A. (2013). *Pengolahan Citra Teori dan Aplikasi*. ANDI, Yogyakarta.
- Gonzales, R. C., dan Woods, R. E. (2002). *Digital Image Processing Second Edition*. Publishing House of Electronics Industry, Beijing.
- Keller, J. M., Gray, M. R., dan Givens, J. A. (1985). A Fuzzy K-Nearest Neighbor Algorithm. *Systems, Man and Cybernetics, IEEE Transactions on*, (4), pp. 580-585.
- Li, D., Deogun, J. S., dan Wang, K. (2007). Gene Function Classification Using Fuzzy K-Nearest Neighbor Approach. In *Granular Computing, GRC 2007, IEEE International Conference*. IEEE.
- Martin, E. (2003). *Pap-Smear Classification*, Doctoral dissertation, MSc Thesis, Technical University of Denmark, Oersted-DTU, Automation.
- Mariarputham, E. J., dan Stephen, A. (2015). Nominated Texture Based Cervical Cancer Classification. *Hindawi Publishing Corporation Computational and Mathematical Methods in Medicine*, 2015, pp. 1-10.
- Bora, K., Chowdhury, M., Mahanta, L. B., Kundu, M. K., dan Das, A.K. (2017). Automated classification of Pap smear images to detect cervical dysplasia. *Computer Methods and Programs in Biomedicine*, 138, pp. 31-47.

- Costa, L.F. dan Cesar, R.M. (2001). *Shape Analysis and Classification Theory and Practice*. CRC Press LLC, Florida.
- Waldchen, J., dan Mader, P. (2017). Plant Species Identification Using Computer Vision Techniques: A Systematic Literature Review. *Archives of Computational Methods in Engineering*, pp. 1-37.
- Mahanta, L. B., Nath, D. C., dan Nath C. K.(2012). Cervix Cancer Diagnosis from Pap Smear Images Using Structure Based Segmentation and Shape Analysis. *Journal of Emerging Trends in Computing and Information Sciences*, 3(2), pp. 245-249.
- Norup, J. (2005). *Classification of pap-smear data by transductive neuro-fuzzy methods*, Master Thesis, Technical University of Denmark, Oersted-DTU, Automation.
- Labeit, A., Peinemann, F., dan Kediri, A. (2013). Cervical Cancer Screening Service Utilisation in UK. *Scientific Report*, 3, pp. 1-9.
- Hallinan, J. (1999). *Detection of malignancy associated changes in cervical cells using statistical and evolutionary computation techniques*, Ph.D. Thesis, University of Queensland.
- Malm, P. (2013). *Image Analysis in Support of Computer-Assisted Cervical Cancer Screening*, Digital Comprehensive Summaries of Uppsala Dissertations from the faculty of science and Technology, UPPSALA UNIVERSITET.
- Purnomo, M. H. (2010). *Konsep Pengolahan Citra Digital dan Ekstraksi Fitur*. GRAHA ILMU, Yogyakarta.
- Arlot, S., dan Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistic surveys*, 4, pp. 40-70.
- Zhang, D., dan Lu, G. (2004). Review of shape representation and description techniques. *Pattern recognition*, 37(1), pp. 1-19.
- Patel, M. N., dan Tandel, P. (2016). A Survey on Feature Extraction Techniques for Shape based Object Recognition. *International Journal of Computer Applications*, 137(6), pp. 16-20.

- Najafabadi, S. S. M., dan Fazarani, L. (2012). Shape analysis of common bean (*Phaseolus vulgaris* L.) seeds using image analysis. *International Research Journal of Applied and Basic Sciences*, 3(8), pp. 1619-1623.
- Greenblatt, R. (2005). Human papillomaviruses: Diseases, diagnosis, and possible vaccine. *Clinical Microbiology Newsletter*, 27(18), pp. 139-145.
- World Health Organization. (2006). *Comprehensive cervical cancer control: A guide to essential practice*, WHO Press.
- Mbaga, A. H., dan Zhijun, P. (2015). Pap Smear Images Classification for Early Detection of Cervical Cancer. *International Journal of Computer Applications*, 118(7), pp. 10-16.
- Khusna, D. A., Nugroho, H. A., dan Soesanti, I. (2016). Analysis of shape feature for lesion classification in breast ultrasound images. In *ADVANCES SCIENCE AND TECHNOLOGY FOR SOCIETY, Proceedings of the 1st International Conference and Technology 2015 (ICST-2015)*, pp. 1-6.
- Shen, L., Rangayyan, R. M., dan Desautels, J. L. (1994). Application of shape analysis to mammographic calcifications. *IEEE Transaction on Medical Imaging*, 13(2), pp. 263-274.
- Mehnert, A. (2003). *Image analysis for the study of chromatin distribution in cell nuclei with application to cervical cancer screening*, Ph.D Thesis, School of Information Technology and Electrical Engineering, The University of Queensland.
- Tan, P., Steinbach, M., dan Kumar, V. (2006). *Introduction to Data Mining*. Pearson Education, New York.
- Trevor, H. Robert, T., dan Friedman J. (2008). *The elements of statistical learning data mining, inference, and prediction*. Springer, California.
- Pap-Smear (Dtu/Herlev) Databases, 2011. [Online].  
<http://mde-lab.aegean.gr/index.php/downloads> (Diakses 10 Pebruari 2017).


**[Halaman ini sengaja dikosongkan]**




## LAMPIRAN 1

Hasil uji coba fitur tekstur untuk klasifikasi sel serviks pada citra *pap smear*


1. Akurasi klasifikasi citra acuan dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ), uRLBP ( $P=8,R=2$ ), dan uRLBP ( $P=8,R=3$ )




2. Akurasi klasifikasi citra acuan tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ), uRLBP ( $P=8,R=2$ ), dan uRLBP ( $P=8,R=3$ )



3. Akurasi klasifikasi citra yang dirotasi beberapa arah untuk dua kategori sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ), uRLBP ( $P=8,R=2$ ), dan uRLBP ( $P=8,R=3$ )



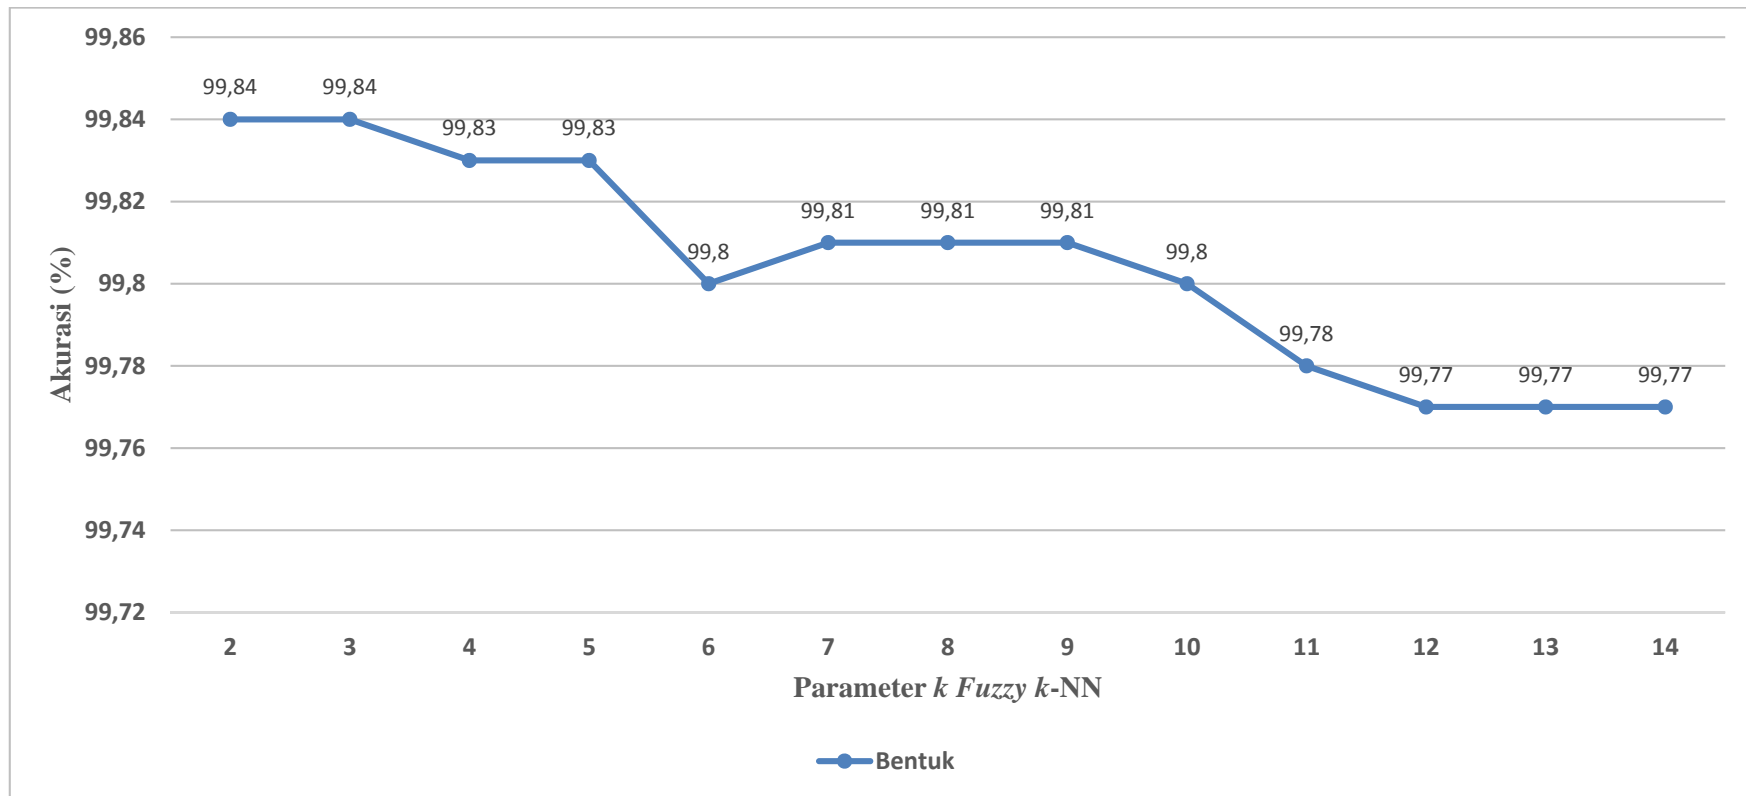
4. Akurasi klasifikasi citra yang dirotasi beberapa arah untuk tujuh kelas sel berdasarkan fitur tekstur uRLBP ( $P=8,R=1$ ), uRLBP ( $P=8,R=2$ ), dan uRLBP ( $P=8,R=3$ )




## LAMPIRAN 2

Hasil uji coba fitur bentuk untuk klasifikasi sel serviks pada citra *pap smear*

1. Akurasi klasifikasi citra yang dirotasi beberapa arah untuk dua kategori sel berdasarkan fitur bentuk.



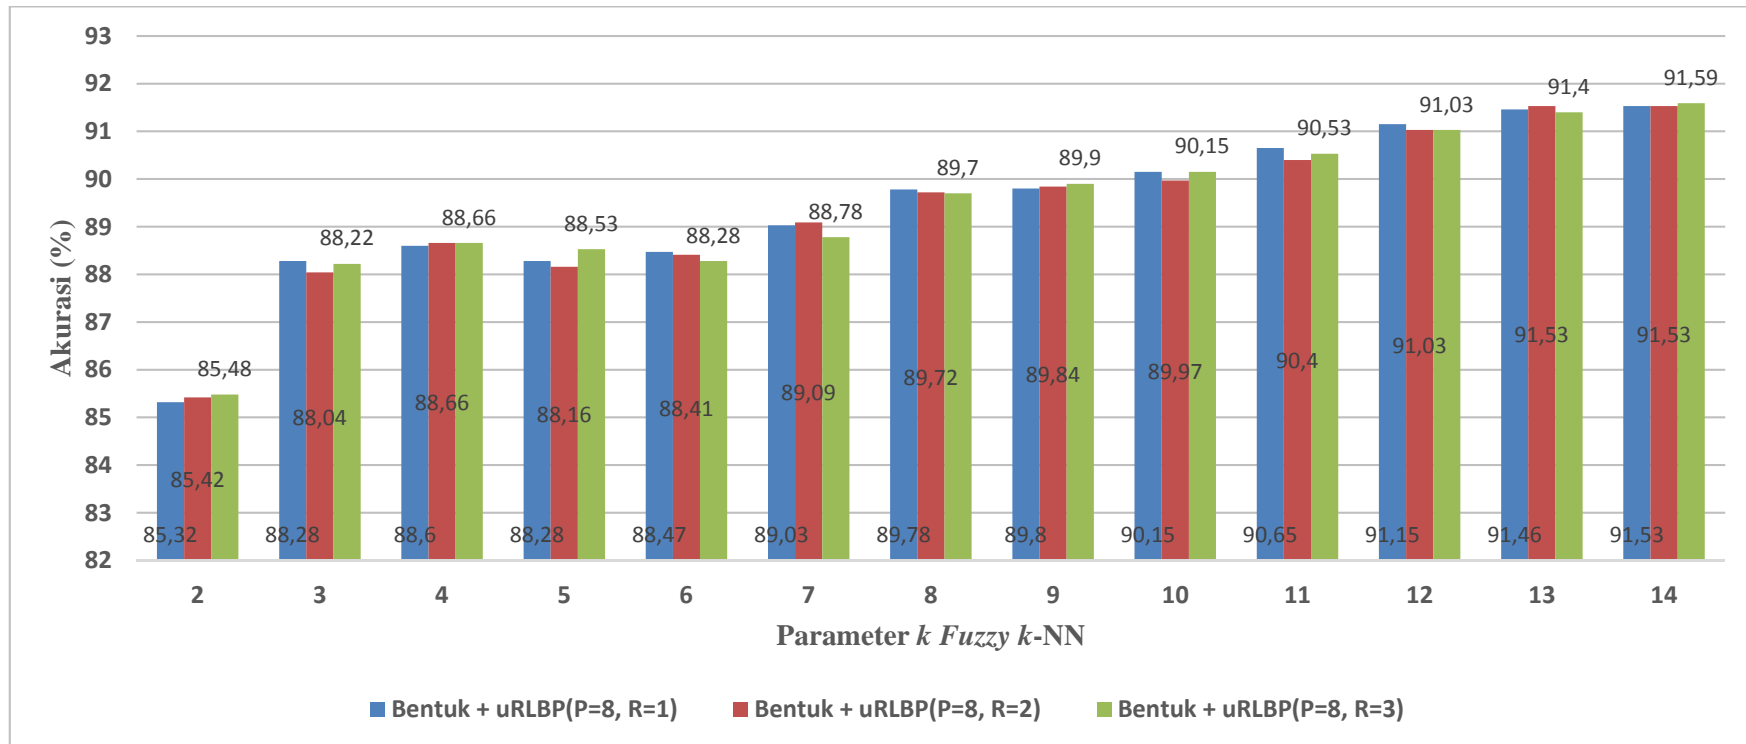
2. Akurasi klasifikasi citra yang dirotasi beberapa arah untuk tujuh kelas sel berdasarkan fitur bentuk.



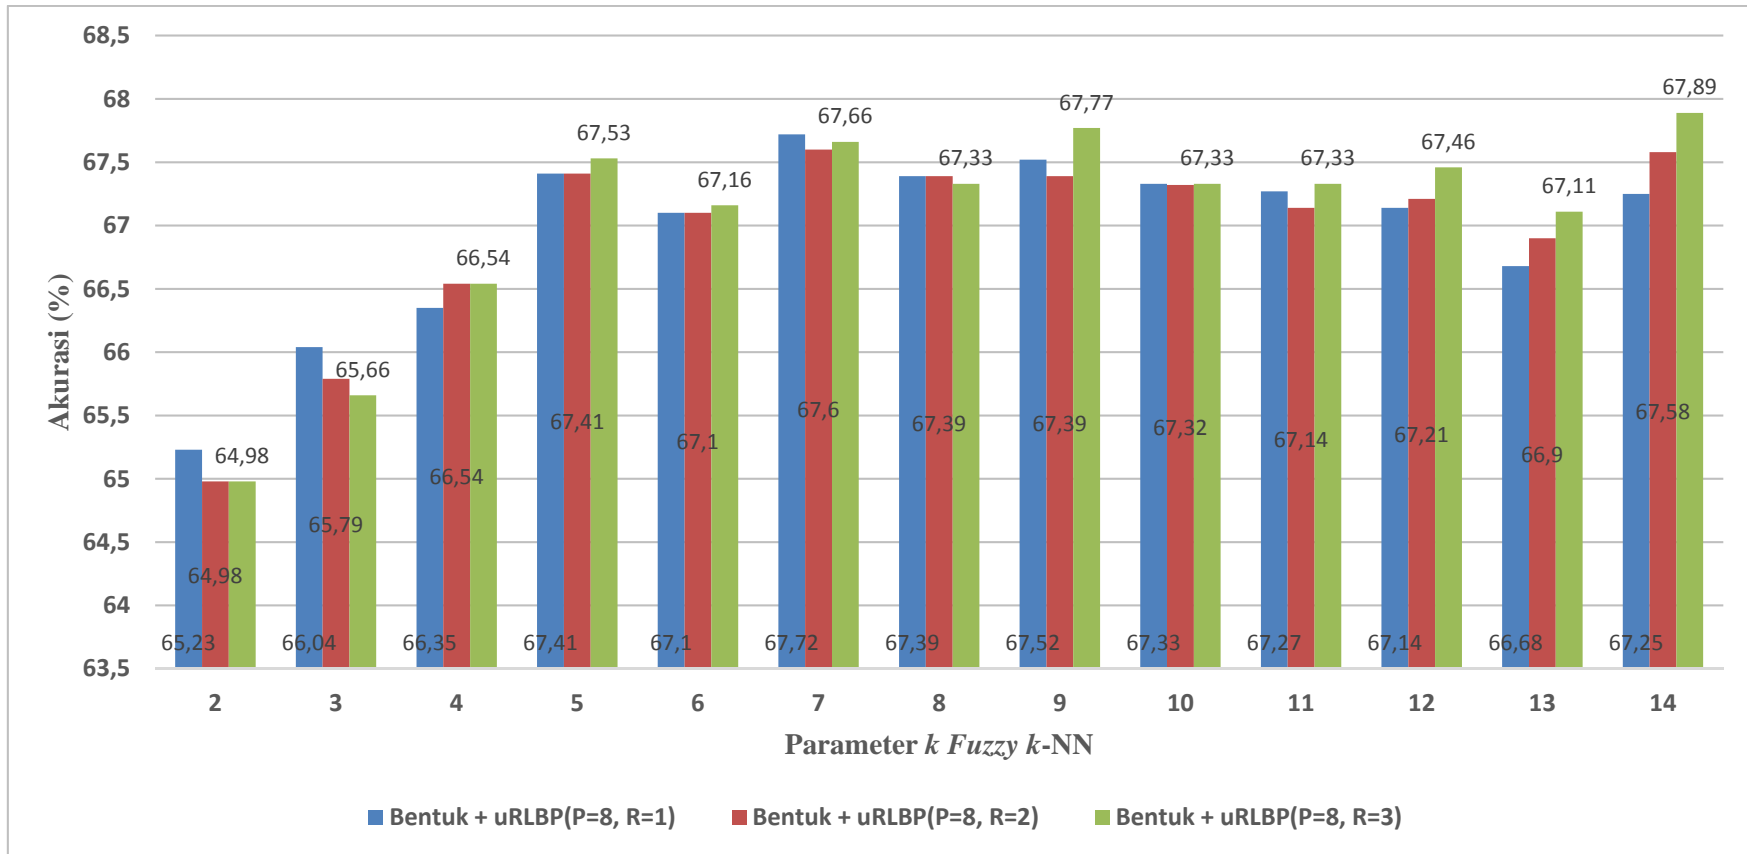
### LAMPIRAN 3

Hasil uji coba kombinasi fitur untuk klasifikasi sel serviks pada citra *pap smear*

1. Akurasi klasifikasi citra yang dirotasi beberapa arah untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur dengan variasi parameter ( $P=8,R=1$ ), ( $P=8,R=2$ ), dan ( $P=8,R=3$ ) pada uRLBP.



2. Akurasi klasifikasi citra yang dirotasi beberapa arah untuk tujuh kelas sel berdasarkan kombinasi fitur bentuk dan fitur tekstur dengan variasi parameter  $(P=8,R=1)$ ,  $(P=8,R=2)$ , dan  $(P=8,R=3)$  pada uRLBP.





## LAMPIRAN 4

Matrik konvusi hasil uji coba kombinasi fitur untuk klasifikasi sel serviks pada citra *pap smear*

1. Matrik konfusi hasil klasifikasi kombinasi fitur bentuk deskriptor regional dan fitur tekstur *Uniform Rotated Local Binary Pattern* (uRLBP ( $P=8,R=3$ )) untuk dua kategori sel.

Kelas Asli	Hasil Klasifikasi Kombinasi Fitur <i>k=14 Fuzzy k-NN</i>	
	Normal	Abnormal
Normal	1550	144
Abnormal	396	4329

$$Akurasi = \left( \frac{1550 + 4329}{6419} \right) \times 100 = \left( \frac{5879}{6419} \right) \times 100 = 91.59 \%$$

2. Matrik konfusi hasil klasifikasi kombinasi fitur bentuk deskriptor regional dan fitur tekstur *Uniform Rotated Local Binary Pattern* (uRLBP ( $P=8,R=3$ )) untuk tujuh kelas sel.


Kelas Asli	Hasil Klasifikasi Kombinasi Fitur $k=14$ Fuzzy $k$ -NN						
	<i>Normal squamous</i>	<i>Intermediate squamous</i>	<i>Columnar</i>	<i>Mild dysplasia</i>	<i>Moderate dysplasia</i>	<i>Severe dysplasia</i>	<i>Carcinoma in situ</i>
<i>Normal squamous</i>	426	72	4	16	0	0	0
<i>Intermediate squamous</i>	144	334	0	12	0	0	0
<i>Columnar</i>	0	0	606	4	52	4	20
<i>Mild dysplasia</i>	40	24	89	921	192	8	0
<i>Moderate dysplasia</i>	0	0	184	120	662	52	4
<i>Severe dysplasia</i>	0	0	316	36	164	779	84
<i>Carcinoma in situ</i>	0	0	124	12	92	192	630

$$Akurasi = \left( \frac{426 + 334 + 606 + 921 + 662 + 779 + 630}{6419} \right) \times 100 = \left( \frac{4358}{6419} \right) \times 100 = 67.89 \%$$


## LAMPIRAN 5

Hasil uji coba perbandingan kombinasi fitur untuk klasifikasi sel serviks pada citra *pap smear*


- Perbandingan akurasi klasifikasi citra yang dirotasi beberapa arah untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur uRLBP( $P=8, R=1$ ) dengan kombinasi fitur sebelumnya.




2. Perbandingan akurasi klasifikasi citra yang dirotasi beberapa arah untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur uRLBP( $P=8,R=2$ ) dengan kombinasi fitur sebelumnya.




3. Perbandingan akurasi klasifikasi citra yang dirotasi beberapa arah untuk dua kategori sel berdasarkan kombinasi fitur bentuk dan fitur tekstur uRLBP( $P=8,R=3$ ) dengan kombinasi fitur sebelumnya.



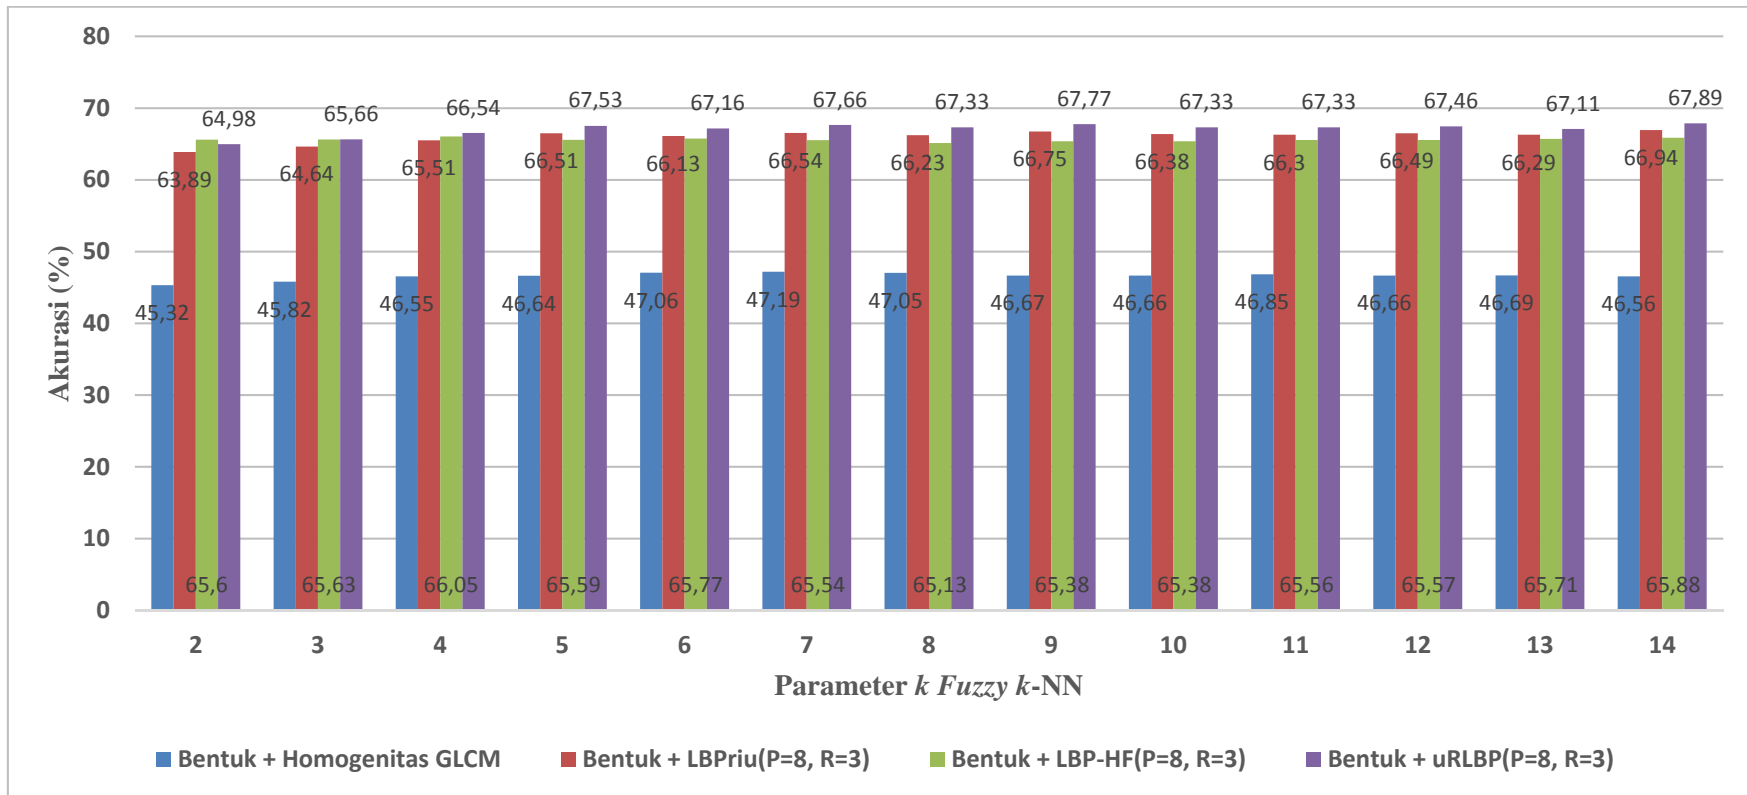
4. Perbandingan akurasi klasifikasi citra yang dirotasi beberapa arah untuk tujuh kelas sel berdasarkan kombinasi fitur bentuk dan fitur tekstur uRLBP( $P=8, R=1$ ) dengan kombinasi fitur sebelumnya.



5. Perbandingan akurasi klasifikasi citra yang dirotasi beberapa arah untuk tujuh kelas sel berdasarkan kombinasi fitur bentuk dan fitur tekstur uRLBP( $P=8,R=2$ ) dengan kombinasi fitur sebelumnya.



6. Perbandingan akurasi klasifikasi citra yang dirotasi beberapa arah untuk tujuh kelas sel berdasarkan kombinasi fitur bentuk dan fitur tekstur uRLBP( $P=8,R=3$ ) dengan kombinasi fitur sebelumnya.





## LAMPIRAN 6

Panjang fitur (dimensi fitur) dan keterangan fitur

### 1. Dimensi Fitur

Fitur	Dimensi Fitur		
	Panjang Fitur Bentuk	Panjang Fitur Tekstur	Panjang Fitur Kombinasi
Bentuk + Homogenitas GLCM	8	1	9
Bentuk + LBP <sup>riu</sup>	4	10	14
Bentuk + LBP-HF	4	38	42
Bentuk + uRLBP	4	59	63

### 2. Keterangan Fitur

Fitur	Fitur Bentuk								Fitur Tekstur
	Nukleus					Sel		Nukleus-Sitoplasma	Nukleus
Bentuk + Homogenitas GLCM	Area	<i>Compactness</i>	<i>Major Axis Length</i>	<i>Minor Axis Length</i>	Aspek Rasio	Area	<i>Compactness</i>	Rasio N/C	Homogenitas GLCM
Bentuk + LBP <sup>riu</sup>	Area	<i>Compactness</i>	-	-	-	Area	<i>Compactness</i>	-	LBP <sup>riu</sup>
Bentuk + LBP-HF	Area	<i>Compactness</i>	-	-	-	Area	<i>Compactness</i>	-	LBP-HF
Bentuk + uRLBP	Area	<i>Compactness</i>	-	-	-	Area	<i>Compactness</i>	-	uRLBP



## BIOGRAFI PENULIS



Mohammad Sholik, anak ketiga dari empat bersaudara, lahir di Kota Gresik Jawa Timur dari pasangan H. Mohammad Yasin (alm) dan Salasatun. Mulai masuk pendidikan formal di SDN Negeri 3 Lowayu Dukun Gresik (1988 - 1994). Madrasah Tsanawiyah Hidayatus Salam Lowayu Dukun Gresik (1994 – 1997). SMA Laboratorium Universitas Negeri Malang (1999 – 2001). Studi jenjang sarjana di Universitas 17 Agustus 1945 Surabaya mengambil jurusan Teknik Informatika (2007 – 2011). Melanjutkan studi pascasarjana jurusan Teknik Informatika Institut Teknologi Sepuluh Nopember Surabaya pada tahun 2013. Penulis juga pernah menempuh pendidikan nonformal pesantren diantaranya PP. Al-Muhtarom Gresik (1990 – 1991). PP. Mambaus Sholihin Manyar Gresik (1997). PP. Tebuireng Jombang (1998 – 1999). PP. Miftahul Huda Malang (Gading Pesantren) (1999 – 2001). PP. Hidayatulloh Gresik (2012 – Sekarang). Penulis dapat dihubungi melalui email : [sholih.archive@gmail.com](mailto:sholih.archive@gmail.com).