



TESIS - KI092361

Ekstraksi Ciri Tekstur Menggunakan *Improved Completed Robust Local Binary Pattern* untuk Klasifikasi Citra Batik

ARRIE KURNIAWARDHANI
NRP.5112201056

DOSEN PEMBIMBING 1
Dr.Eng. Nanik Suciati, S.Kom., M.Kom.
Isye Ariesanti, S.Kom, M.Phil.

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



THESIS - KI092361

Texture Feature Extraction Using Improved Completed Robust Local Binary Pattern For Batik Image Classification

ARRIE KURNIAWARDHANI
NRP.5112201056

Supervisor
Dr.Eng. Nanik Suciati, S.Kom., M.Kom.
Isye Arieshanti, S.Kom, M.Phil.

MAGISTER PROGRAM
INTELLIGENCE COMPUTATIONAL AND VISUALIZATION
DEPARTMENT OF INFORMATICS ENGINEERING
FACULTY OF INFORMATION TECHNOLOGY
INSTITUT TEKNOLOGI SEPULUH NOPEMBER SURABAYA
2014

Ekstraksi Ciri Tekstur Menggunakan *Improved Completed Robust Local Binary Pattern* untuk Klasifikasi Citra Batik

Nama Mahasiswa : Arrie Kurniawardhani

NRP : 5112201056

Dosen Pembimbing : Dr.Eng. Nanik Suciati, S.Kom., M.Kom.
Isye Arieshanti, S.Kom, M.Phil.

ABSTRAK

Untuk membantu proses pendokumentasian citra batik, dibutuhkan sistem klasifikasi yang cukup handal dalam mengklasifikasi dan mengidentifikasi citra batik. Salah satu bagian penting dari sistem klasifikasi adalah metode ekstraksi ciri. Pemilihan metode ekstraksi ciri yang tepat sangat dibutuhkan agar dapat mencapai akurasi yang tinggi pada sistem klasifikasi. Metode ekstraksi ciri tekstur menjadi pilihan pada sistem klasifikasi kali ini, karena batik direpresentasikan berdasarkan motif dasarnya.

Salah satu metode ekstraksi ciri tekstur yang handal adalah *Local Binary Pattern* (LBP). LBP adalah metode yang sederhana namun efisien dalam merepresentasikan ciri, serta *gray-scale invariant*. Beberapa penelitian telah diajukan untuk meningkatkan kinerja LBP. Salah satunya adalah *Completed Robust Local Binary Pattern* (CRLBP), diusulkan oleh Zhao untuk mengatasi kelemahan CLBP yang sensitif terhadap *noise*. Namun, CRLBP tidak *invariant* terhadap rotasi.

Dari permasalahan tersebut, penelitian kali ini mengusulkan pendekatan baru dari CRLBP, dengan cara menyisipkan metode LBPROT ke dalam algoritma CRLBP. LBPROT adalah salah satu metode yang diusulkan untuk memperbaiki kelemahan LBP agar *invariant* terhadap rotasi. Pendekatan yang disebut di atas dinamakan *Improved Completed Robust Local Binary Pattern* (ICRLBP).

ICRLBP memiliki metode dasar yang sama dengan CRLBP. ICRLBP memiliki 3 histogram ciri yaitu *ICRLBP_Sign*, *ICRLBP_Magnitude*, dan *ICRLBP_Center*. Algoritma LBPROT disisipkan setelah *sign vector* dan *magnitude vector* diperoleh. LBPROT mencari kombinasi nilai biner yang terkecil dari nilai biner *sign vector* dan *magnitude vector* pada setiap piksel. Kombinasi nilai biner terkecil tersebut dikonversi ke bilangan desimal. Dari nilai desimal tersebut histogram ciri ICRLBP disusun. Selanjutnya, Histogram ciri ICRLBP menjadi data masukkan ke klasifikasi *Probabilistic Neural Network*. Kinerja sistem diukur menggunakan akurasi. Hasil uji coba menunjukkan bahwa ICRLBP dapat meningkatkan akurasi sebesar 17,39% dan lebih cepat 300 kali lipat dari CRLBP pada dataset Batik. Hal ini menunjukkan bahwa ICRLBP lebih handal dibandingkan CRLBP.

Kata kunci: *Batik, klasifikasi, ekstraksi ciri tekstur, completed robust local binary pattern, rotation invariant, probabilistic neural network.*

Texture Feature Extraction Using *Improved Completed Robust Local Binary Pattern* For Batik Image Classification

Name : Arrie Kurniawardhani
NRP : 5112201056
Supervisor : Dr. Eng. Nanik Suciati, S.Kom., M.Kom.
Isye Ariesianti, S.Kom, M.Phil.

ABSTRACT

Assisting the process of batik image documentation, a reliable classification system is needed. One important part in the classification system is the feature extraction method. Selecting an appropriate feature extraction method is an urgent issue in order to achieve high accuracy in the classification system. Texture feature extraction method is chosen at this study, because batik can be represented by its basic pattern or motif.

One of reliable texture feature extraction methods is Local Binary Pattern (LBP). LBP is a simple but efficient method and gray-scale invariant, namely it is not affected at uneven illumination issue on the image, because LBP describes texture locally. Some studies have been proposed to improve the performance of LBP, such as Completed Robust Local Binary Pattern (CRLBP). CRLBP is proposed by Zhao to overcome the weaknesses of CLBP that sensitive to noise. However, CRLBP is not invariant to rotation.

From that problem, in this study, a new approach of CRLBP is proposed. CRLBP algorithm will be inserted by LBPROT algorithm. LBPROT is one of improved LBP methods that proposed to overcome the LBP weakness which is not rotation invariant. The approach is called Improved Completed Robust Local Binary Pattern (ICRLBP).

ICRLBP has the same basic method to CRLBP. ICRLBP has three feature histograms namely ICRLBP_Sign, ICRLBP_Magnitude, and ICRLBP_Center. After sign vector and magnitude vector is gotten, LBPROT algorithm is inserted. LBPROT looks for the smallest binary combination value of sign binary vector and magnitude binary vector in each piksel. Futhermore, the smallest binary combination value is converted to decimal. That decimal value is used to build the ICRLBP histograms.

ICRLBP histograms as input data is fed into classification system using Probabilistic Neural Network. The performance of classification system is evaluated using accuracy. The result experiments show that the accuracy and the speed of ICRLBP increased by 17.39% and 300 times for Batik datasets, respectively. It show that ICRLBP is proven can improve the performance of CRLBP.

Keywords: *Batik, classification, texture feature extraction, completed robust local binary pattern, rotation invariant, probabilistic neural network.*

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

di

Institut Teknologi Sepuluh Nopember Surabaya

oleh:

Arrie Kurniawardhani

Nrp. 5112 201 056

Tanggal Ujian : 17 Juli 2014

Periode Wisuda : September 2014

Disetujui oleh:

1. Dr. Eng. Nanik Suciati, S.Kom., M.Kom.
NIP. 19710428 199412 2 001



.....
(Pembimbing1)

2. Isye Arieshanti, S.Kom, M.Phil.
NIP. 19780412 200604 2 001



.....
(Pembimbing 2)

3. Dr. Chastine Fatichah, S.Kom., M.Kom
NIP. 19751220 200112 2 002



.....
(Penguji 1)

4. Anny Yuniarti, S.Kom.,M.Com.Sc
NIP. 198106222005012002



.....
(Penguji 2)

5. Wijayanti Nurul Khotimah, S.Kom.,M.Sc
NIP. 19860312 201212 2 004



.....
(Penguji 3)



KATA PENGANTAR

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Alhamdulillahirabbil'amin, segala puji bagi Allah SWT, yang telah melimpahkan rahmat dan hidayah-Nya sehingga penulis bisa menyelesaikan Tesis yang berjudul *“Ekstraksi Ciri Tekstur Menggunakan Improved Completed Robust Local Binary Pattern untuk Klasifikasi Citra Batik”* dengan tepat waktu.

Pengerjaan Tesis ini merupakan suatu kesempatan yang sangat berharga bagi penulis, karena dengan pengerjaan Tesis ini, penulis bisa memperdalam, meningkatkan, serta mengimplementasikan apa yang telah didapatkan penulis selama menempuh perkuliahan di Teknik Informatika ITS.

Terselesainya buku Tesis ini, tidak terlepas dari bantuan dan dukungan semua pihak. Oleh karena itu, penulis ingin menyampaikan rasa terima kasih kepada:

1. Allah SWT atas limpahan rahmat-Nya sehingga penulis dapat menyelesaikan Tesis ini dengan baik.
2. Rasulullah Muhammad SAW sebagai penyampai risalah dan sumber inspirasi bagi penulis untuk selalu memberikan yang terbaik.
3. Bapak dan ibu nomor satu sedunia, yang telah memberikan semangat, kasih sayang, perhatian serta dukungan dan doa untuk penulis. Semoga Allah membalas beribu kebaikan dan mengasihi mereka sebagaimana mereka mengasihi penulis di waktu kecil.
4. Pak Agus Eko Minarno, dan Mas Fitri Bimantoro you are the best, masih banyak keinginan yang belum tercapai, mas Daniel Swanjaya thanks printernya, Michael thanks for TOEFL comprehension.
5. Dr. Eng. Nanik Suciati, S.Kom, M.Kom, Isye Arieshanti, S.Kom, M.Phil selaku Dosen Pembimbing yang telah memberikan bimbingan kepada penulis dalam menyelesaikan Tesis ini.
6. Dr. H. Agus Zainal Arifin, S.Kom, M.Kom, selaku Dekan Fakultas Teknologi Informasi ITS.

7. Waskitho Wibisono, S.Kom., M.Eng., Ph.D., selaku Koordinator S2 Jurusan Teknik Informatika ITS.

8. Dr Chastine Fatchah, S.Kom., M.Kom., Anny Yuniarti, S.Kom.,M.Com.Sc., Wijayanti Nurul Khotimah, S.Kom., M.Sc. selaku penguji tesis yang telah memberikan banyak masukan.

9. Teman-teman S2 Teknik Informatika angkatan 2010, 2011, dan 2012 yang meramaikan Lab dan membantu penulis memahami makalah ilmiah.

10. Juga tidak lupa kepada semua pihak yang belum sempat disebutkan satu per satu disini yang telah membantu terselesaikannya Tesis ini.

Sebagai manusia biasa, penulis menyadari bahwa Tesis ini masih jauh dari kesempurnaan dan memiliki banyak kekurangan. Sehingga dengan segala kerendahan hati, penulis mengharapkan saran dan kritik yang membangun dari pembaca.

Surabaya, 22 Juli 2014

Penulis

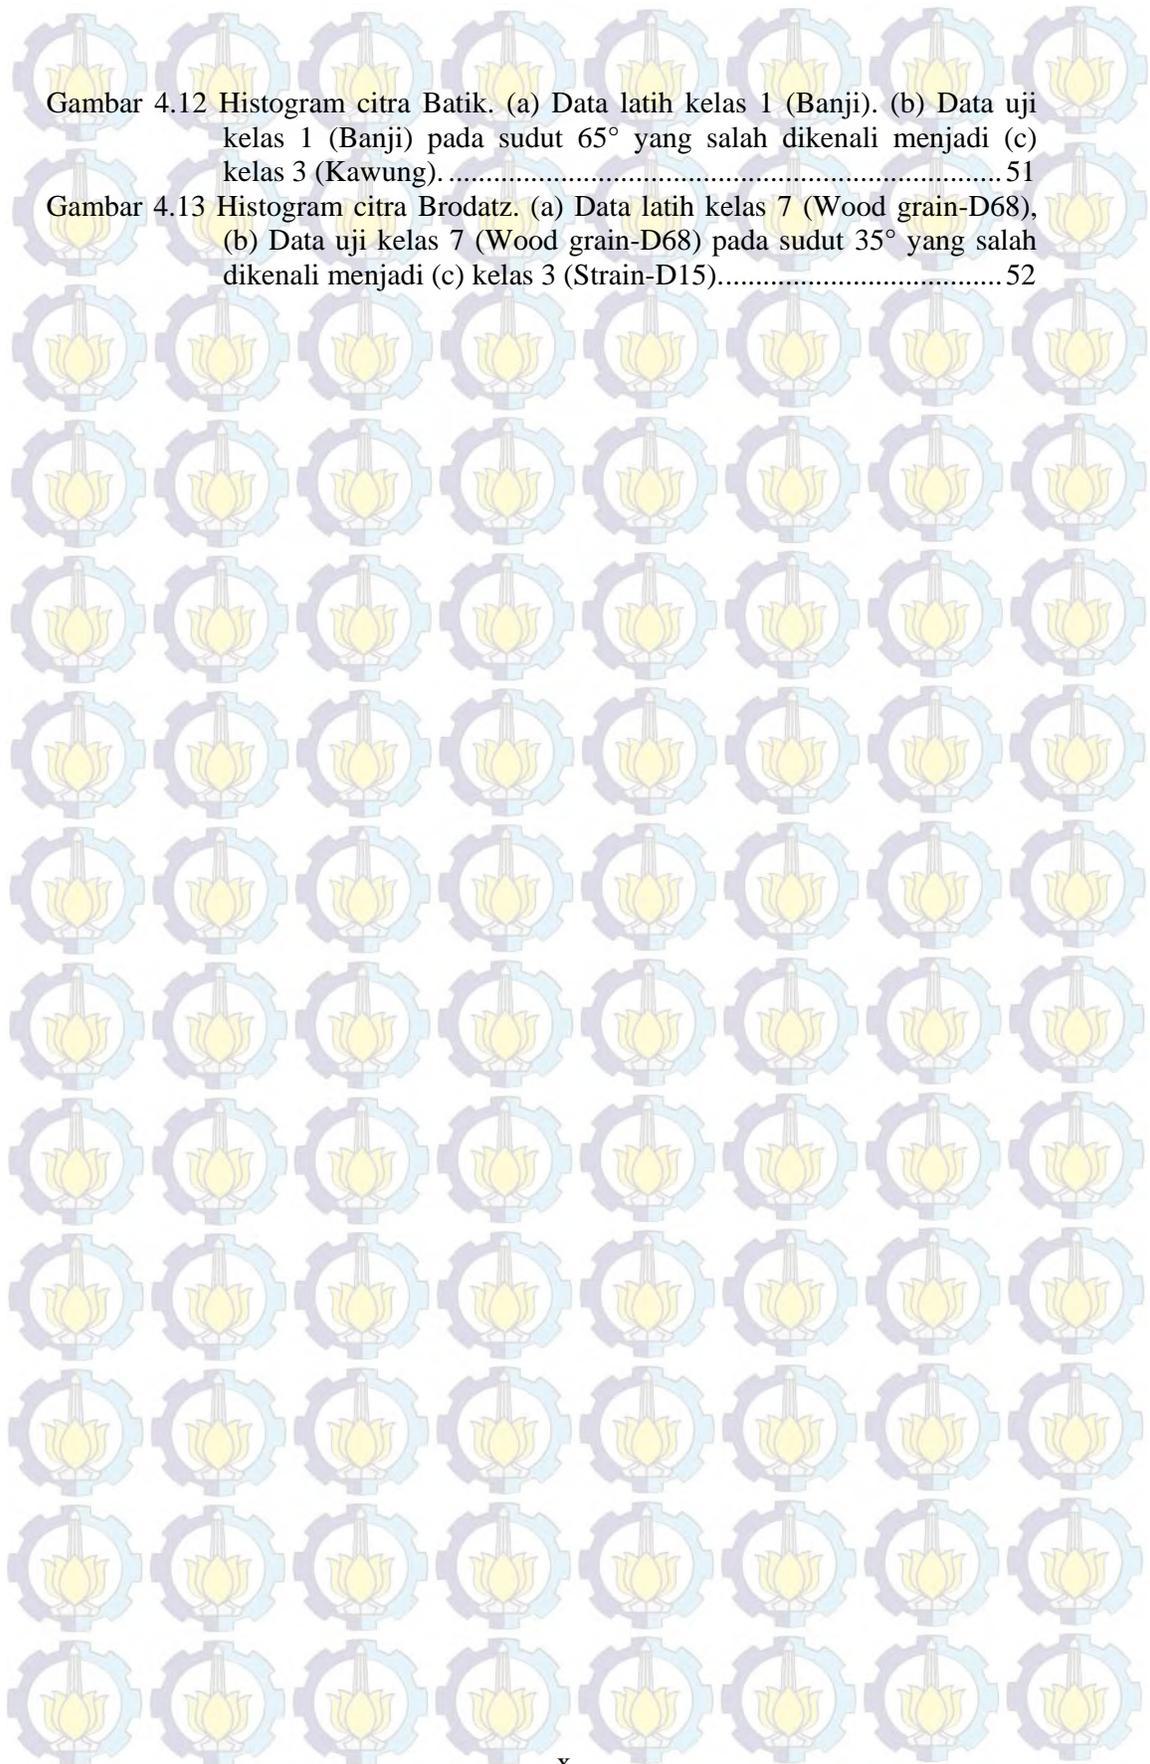
DAFTAR ISI

ABSTRAK.....	i
ABSTRACT.....	iii
KATA PENGANTAR	v
DAFTAR ISI.....	vii
DAFTAR GAMBAR	ix
DAFTAR GAMBAR	xi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan dan Manfaat Penelitian.....	5
1.5 Kontribusi Penelitian	5
BAB 2	7
DASAR TEORI DAN KAJIAN PUSTAKA.....	7
2.1 Batik	7
2.1.1 Penggolongan Motif Batik	7
2.2 <i>Local Binary Pattern</i>	10
2.3 <i>Completed Robust Local Binary Pattern</i>	13
2.4 Penggabungan histogram.....	16
2.4.1 <i>Concatenation</i>	16
2.4.2 <i>Jointly</i>	17
2.5 LBP yang <i>invariant</i> terhadap rotasi	18
2.6 <i>Probabilistic Neural Network</i>	19
2.6.1 Input Layer.....	19
2.6.2 Pattern Layer.....	19
2.6.4 <i>Competitive Layer</i>	20
BAB 3	23
METODE PENELITIAN.....	23
3.1 Rancangan Penelitian.....	23
3.2 Analisis Data	24
3.3 <i>Improved Completed Robust Local Binary Pattern</i>	25
3.4 Perancangan Uji Coba.....	28
3.4.1 Pengujian Ciri	28

3.4.2	Pengujian Metode Penggabungan Histogram	29
3.4.3	Pengujian Metode <i>Padding</i>	29
3.4.4	Pengujian Metode <i>Preprocessing</i>	29
3.4.5	Pengujian Perbandingan CRLBP dengan ICRLBP	30
3.4.6	Pengujian dengan Data Batik	30
3.4.7	Pengujian dengan Data Brodatz	31
3.5	Evaluasi.....	31
BAB 4.....		33
4.1	Lingkungan Uji Coba	33
4.2	Dataset	33
4.3	Uji Coba	36
4.3.1	Pengujian Kombinasi Ciri dan Metode Penggabungan Histogram	36
4.3.2	Pengujian Kinerja ICRLBP pada Masing-masing Sudut Rotasi	38
4.3.3	Pengujian Metode <i>Padding</i>	40
4.3.4	Pengujian Metode <i>Preprocessing</i>	41
4.3.5	Pengujian ICRLBP dengan Ukuran Skala Citra yang Berbeda.....	43
4.3.6	Pengujian Perbandingan CRLBP dengan ICRLBP	44
4.4	Pembahasan	45
BAB 5 KESIMPULAN		55
DAFTAR PUSTAKA.....		57

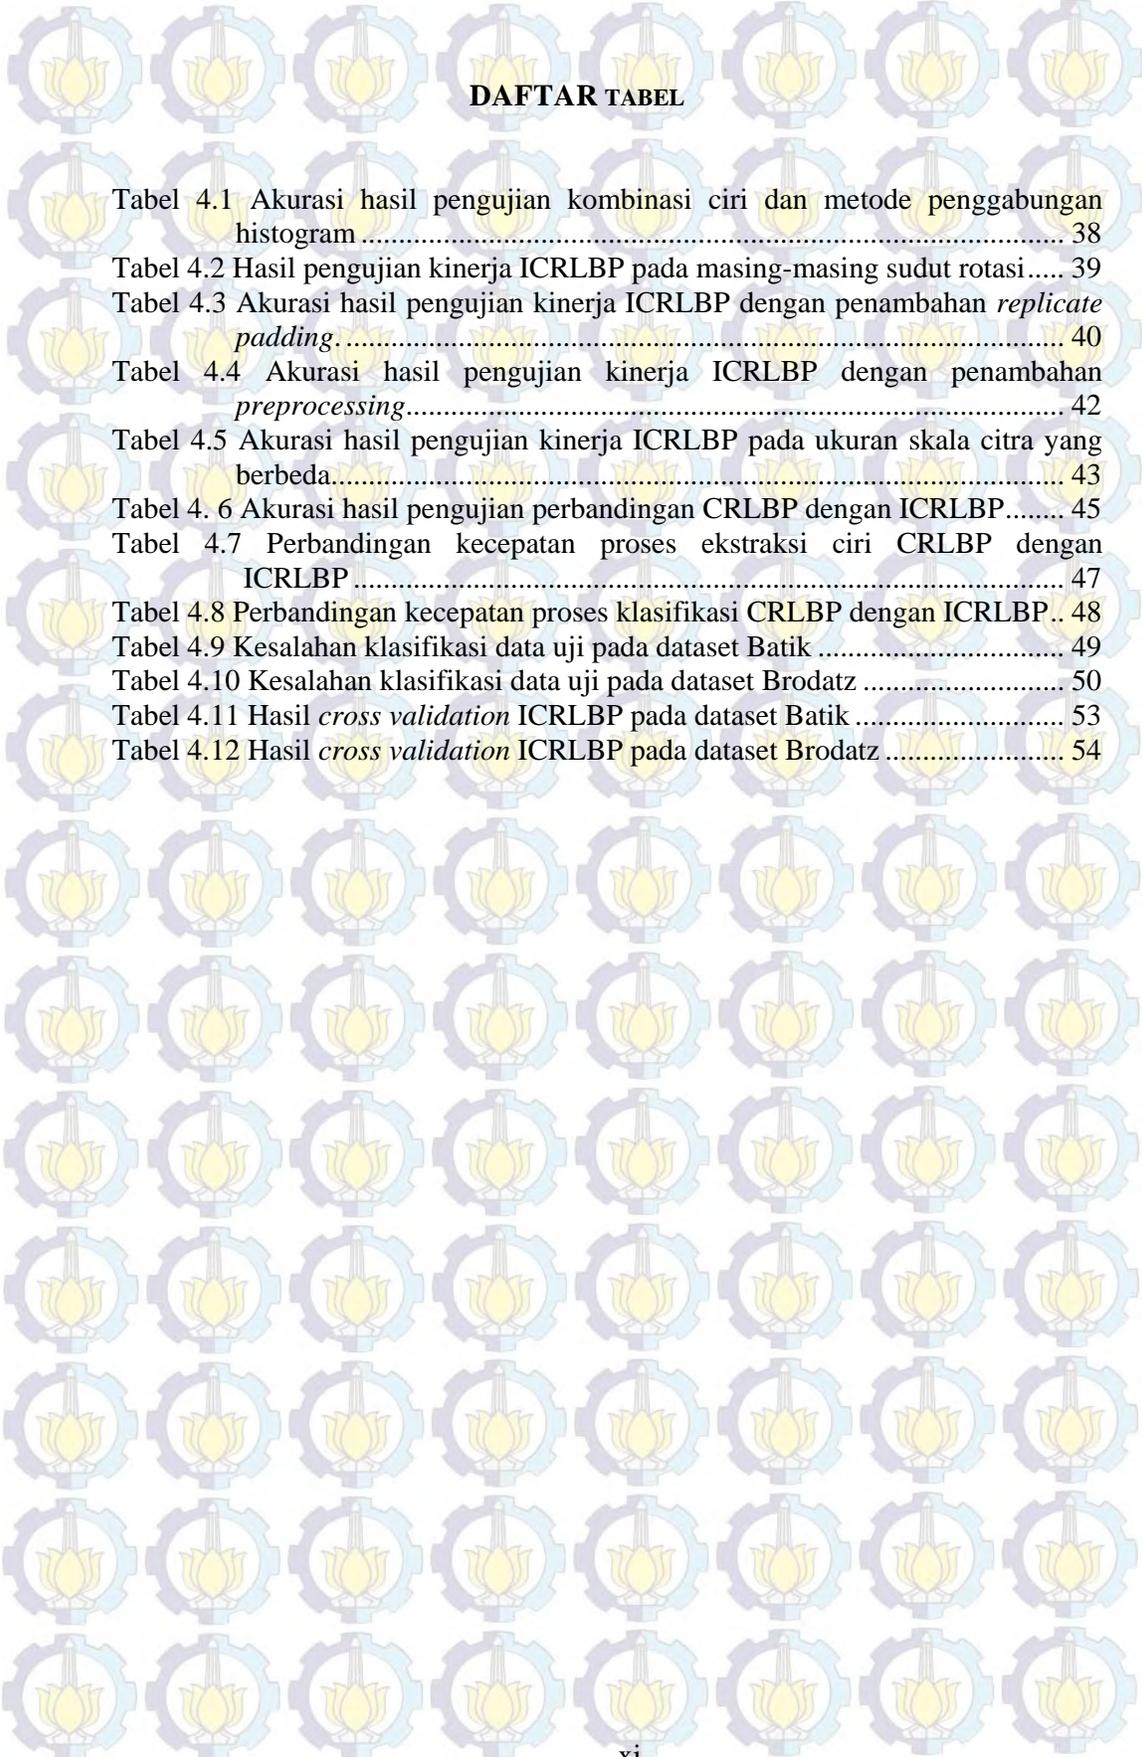
DAFTAR GAMBAR

Gambar 1.1 Kelemahan LBP	3
Gambar 1.2 Kelemahan CLBP.....	3
Gambar 2.1 Motif Batik Geometri. (a) Banji. (b) Ceplok. (c) Kawung. (d) Ganggong. (e) Udan Liris. (f) Parang. (g) Nitik.....	9
Gambar 2.2 Motif Batik Non-Geometri. (a) Semen. (b) Buketan.	10
Gambar 2.3 Motif Batik Sampler. (a) Tambal. (b) Composition.....	10
Gambar 2.4 Operator LBP	11
Gambar 2.5 Ilustrasi Proses LBP. (a) Citra asli. (b) Hasil perbandingan dengan fungsi thresholding. (c) Bobot. (d) Hasil perkalian dengan bobot. (e) Histogram ciri LBP.	12
Gambar 2.6 Ilustrasi Proses CLBP. (a) Citra asli. (b) Perbedaan lokal (dp, R). (c) Sign vector. (d) Magnitude vector.....	14
Gambar 2.7 Concatenation histogram.....	16
Gambar 2.8 Jointly histogram.....	17
Gambar 2.9 Penggeseran nilai biner untuk mencari kombinasi nilai terkecil.....	18
Gambar 2.10 Ilustrasi 36 pola dasar LBPROT	18
Gambar 2.11 Proses LBPROT dengan cara pengindeksan.....	19
Gambar 2.12 Arsitektur PNN.....	20
Gambar 3.1 Data Batik. (a) Banji. (b) Ceplok. (c) Kawung. (d) Nitik. (e) Parang. (f) Udan Liris. (g) Tambal. (h) Semen. (i) Buketan.	24
Gambar 3.2 Data Brodatz. (a) Grass-D9. (b) Bark-D12. (c) Straw-D15. (d) Herringbone weave-D16. (e) woolen cloth-D19. (f) Pressed calf leather-D24. (g) Wood grain-D68. (h) Brick wall-D94. (i) Plastic bubbles-D112.	25
Gambar 3.3 Proses klasifikasi dengan metode ekstraksi ciri tekstur ICRLBP.	26
Gambar 3.4 Proses detail dari klasifikasi Batik. (a) Preprocessing. (b) Ekstraksi ciri.....	27
Gambar 3.5 Ekstraksi ciri dengan metode ICRLBP. (a) ICRLBP_S. (b) ICRLBP_M. (c) ICRLBP_C.	28
Gambar 4.1 Hasil subsampling salah satu citra Batik.....	34
Gambar 4.2 Hasil rotasi salah satu citra Batik	34
Gambar 4.3 Tujuh variasi motif Batik dalam kelas Banji.....	35
Gambar 4.4 Hasil subsampling salah satu citra Brodatz.....	35
Gambar 4.5 Hasil rotasi salah satu citra Brodatz	35
Gambar 4.6 Data uji dengan sudut 45°	39
Gambar 4.7 Data uji scalling pada kelas Ceplok	44
Gambar 4.8 Perbandingan metode ICRLBP dengan CRLBP pada dataset Batik.	46
Gambar 4.9 Perbandingan metode ICRLBP dengan CRLBP pada dataset Brodatz	46
Gambar 4.10 Perbandingan kecepatan proses ekstraksi ciri CRLBP dengan ICRLBP	47
Gambar 4.11 Perbandingan kecepatan proses klasifikasi CRLBP dengan ICRLBP	48



Gambar 4.12 Histogram citra Batik. (a) Data latih kelas 1 (Banji). (b) Data uji kelas 1 (Banji) pada sudut 65° yang salah dikenali menjadi (c) kelas 3 (Kawung)..... 51

Gambar 4.13 Histogram citra Brodatz. (a) Data latih kelas 7 (Wood grain-D68), (b) Data uji kelas 7 (Wood grain-D68) pada sudut 35° yang salah dikenali menjadi (c) kelas 3 (Strain-D15)..... 52



DAFTAR TABEL

Tabel 4.1 Akurasi hasil pengujian kombinasi ciri dan metode penggabungan histogram	38
Tabel 4.2 Hasil pengujian kinerja ICRLBP pada masing-masing sudut rotasi.....	39
Tabel 4.3 Akurasi hasil pengujian kinerja ICRLBP dengan penambahan <i>replicate padding</i>	40
Tabel 4.4 Akurasi hasil pengujian kinerja ICRLBP dengan penambahan <i>preprocessing</i>	42
Tabel 4.5 Akurasi hasil pengujian kinerja ICRLBP pada ukuran skala citra yang berbeda.....	43
Tabel 4.6 Akurasi hasil pengujian perbandingan CRLBP dengan ICRLBP.....	45
Tabel 4.7 Perbandingan kecepatan proses ekstraksi ciri CRLBP dengan ICRLBP	47
Tabel 4.8 Perbandingan kecepatan proses klasifikasi CRLBP dengan ICRLBP..	48
Tabel 4.9 Kesalahan klasifikasi data uji pada dataset Batik	49
Tabel 4.10 Kesalahan klasifikasi data uji pada dataset Brodatz	50
Tabel 4.11 Hasil <i>cross validation</i> ICRLBP pada dataset Batik	53
Tabel 4.12 Hasil <i>cross validation</i> ICRLBP pada dataset Brodatz	54

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Batik adalah corak atau pola tradisional pada kain yang digambar dengan metode tradisional. Batik berasal dari bahasa Jawa, yaitu “ngembat” (menulis) dan “titik” (titik atau *dot*), yang berarti menggambar titik pada kain (Hamidin, 2010). Batik telah diakui oleh UNESCO sebagai salah satu warisan budaya asli dari Indonesia, pada tanggal 2 Oktober 2009. Batik di Indonesia memiliki berbagai macam jenis corak atau pola Batik. Pola-pola tersebut disusun secara berulang untuk menggambarkan motif dasar pada suatu kain secara keseluruhan. Keberulangan motif pada suatu kain Batik dapat disusun baik secara teratur maupun tidak teratur (Haake, 1989). Berdasarkan jenis motif dasar dan sifat keteraturan yang menyusun kain Batik, maka Batik dapat diklasifikasikan berdasarkan motifnya untuk membantu proses dokumentasi.

Salah satu bagian penting yang dapat mendukung keberhasilan proses klasifikasi adalah proses pengenalan motif. Proses pengenalan motif dilakukan dengan cara mengekstraksi ciri dari motif tersebut. Ciri yang digunakan untuk mengenali motif Batik adalah ciri tekstur, karena tekstur dapat mendeskripsikan susunan intensitas dari sekumpulan piksel-piksel yang bertetangga pada citra. Oleh karena itu, dibutuhkan metode ekstraksi ciri tekstur yang tepat agar dapat mencapai akurasi yang tinggi pada proses klasifikasi.

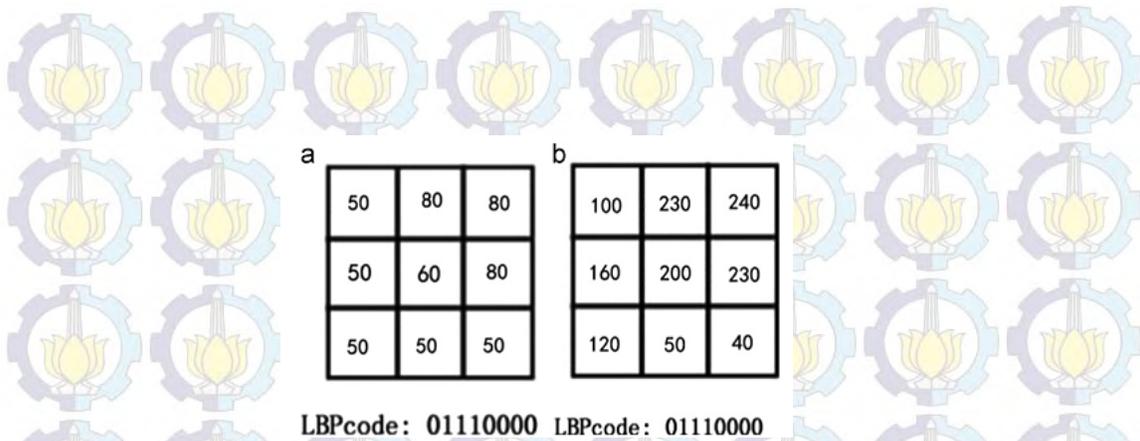
Salah satu metode ekstraksi ciri tekstur yang handal adalah *Local Binary Pattern* (LBP) (Ojala, 1996). LBP adalah metode yang cukup sederhana, namun efisien dalam merepresentasikan ciri tekstur (Ojala, 2002). Operator LBP hanya terdiri dari beberapa piksel tetangga dengan operasi perhitungan yang tidak rumit. Selain itu, LBP merupakan metode yang *gray-scale invariant*, atau tidak terpengaruh pada pencahayaan yang tidak merata pada citra, karena LBP mendeskripsikan tekstur secara lokal.

T. Ojala mengusulkan LBP pertama kali untuk mengekstraksi ciri tekstur pada dataset Brodatz yang terdiri atas 9 kelas. Kinerja LBP dibandingkan dengan

beberapa metode ekstraksi ciri tekstur yang lain, seperti *Gray-level difference method*, *Law's texture measures*, dan *Center-symmetric covariance measures* (Ojala, 1996). Dari penelitian tersebut menunjukkan bahwa LBP dapat mencapai nilai rata-rata error paling rendah dibandingkan metode ekstraksi ciri tekstur yang lain, yaitu 2.3% pada citra berukuran 32x32, dan 12,5% pada citra berukuran 16x16.

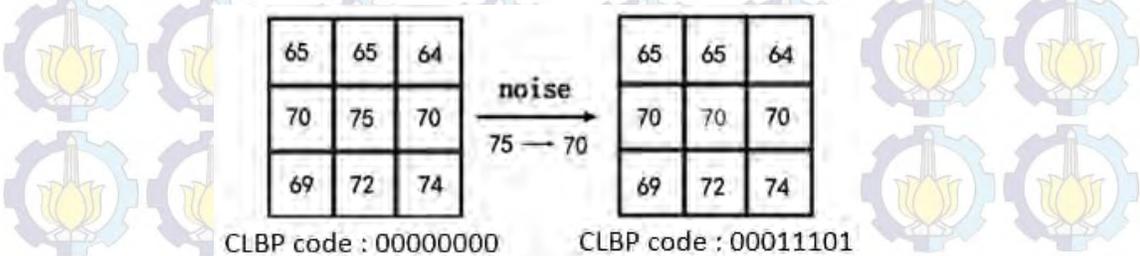
LBP yang *invariant* terhadap rotasi (LBPROT) diusulkan oleh Pietikäinen untuk memperbaiki kinerja dari LBP (Pietikäinen, 2000). Kinerja LBPROT dievaluasi pada dataset Brodatz, yang terdiri atas 15 kelas, kemudian masing-masing citra dirotasi pada tujuh sudut yang berbeda. Pada data latih citra dirotasi 11°, sedangkan pada data uji citra dirotasi 30°, 60°, 90°, 120°, 150°, dan 200°. Nilai rata-rata error LBPROT tidak cukup memuaskan yaitu 39.2% pada citra 64x64 dan 47.7% pada citra 32x32. Namun, saat ciri LBPROT digabung dengan ciri variance lokal (VAR), LBPROT/VAR dapat mencapai nilai rata-rata error yang cukup rendah yaitu 10.1% pada citra 64x64 dan 24.1% pada citra 32x32. Hal ini menunjukkan bahwa kinerja LBPROT dapat meningkat saat digabungkan dengan ciri yang menghitung kekontrasan lokal.

Completed Local Binary Pattern (CLBP) telah diusulkan oleh Guo untuk meningkatkan kinerja LBP (Guo, 2010). LBP memiliki kelemahan dimana beberapa pola struktur yang berbeda memiliki nilai LBP yang sama, seperti ditunjukkan pada Gambar 1.1. Oleh karena itu, CLBP mengusulkan ciri lokal baru, yaitu *CRLB_Sign* (CRLB_S), *CRLB_Magnitudes* (CRLB_M), dan *CRLB_Center* (CRLB_C). CRLB_S memiliki prinsip yang sama dengan LBP, dimana CRLB_S merupakan representasi nilai yang menunjukkan apakah intensitas piksel tetangga lebih kecil atau lebih besar dari intensitas piksel pusat. Sedangkan CRLB_M merupakan representasi besarnya nilai perbedaan antara intensitas piksel tetangga dengan intensitas piksel pusat. CLBP_C merupakan nilai representasi dari intensitas piksel pusat terhadap rata-rata nilai intensitas seluruh citra. Kinerja CLBP dievaluasi pada dataset Outex yang terdiri dari 24 kelas, dataset CURET yang terdiri dari 61 kelas. Dari hasil penelitian tersebut menunjukkan bahwa CLBP dapat meningkatkan nilai rata-rata akurasi sebesar 6,67%, dibandingkan dengan LBP.



Gambar 1.1 Kelemahan LBP

CLBP memiliki kelemahan sensitif pada *noise*, karena nilai intensitas piksel pusat digunakan secara langsung sebagai *thresholding*, seperti ditunjukkan pada Gambar 1.2. Perbaikan CLBP diusulkan oleh Zhao dalam penelitiannya menggunakan *Completed Robust Local Binary Pattern* (CRLBP) (Zhao, 2013). Pada CRLBP, nilai intensitas piksel pusat diganti dengan nilai rata-rata intensitas *gray-level* lokal. Kinerja CRLBP dievaluasi pada dataset Outex yang terdiri dari 24 kelas, dataset CURET yang terdiri dari 61 kelas, dataset UIUC yang terdiri dari 25 kelas, dan dataset XU_HR yang terdiri dari 25 kelas. Dari hasil penelitian tersebut menunjukkan bahwa CRLBP dapat meningkatkan nilai rata-rata akurasi sebesar 2,5%, dibandingkan dengan CLBP.



Gambar 1.2 Kelemahan CLBP

Namun, CRLBP memiliki kelemahan yaitu tidak *invariant* terhadap rotasi. Metode yang diusulkan untuk mengatasi permasalahan tersebut adalah *Improved CRLBP* (ICRLBP). ICRLBP mengembangkan metode CRLBP dengan menyisipkan algoritma LBPROT ke dalam algoritma CRLBP. CRLBP_M menghitung nilai *variance* lokal, karena mencari perbedaan nilai intensitas piksel

tetangga dengan nilai rata-rata intensitas *gray-level* lokal dari piksel pusat.

Sehingga, dengan menyisipkan algoritma LBPROT ke dalam algoritma CRLBP diharapkan dapat meningkatkan kinerja CRLBP.

Histogram ciri yang diperoleh dari proses ekstraksi ciri tekstur menggunakan ICRLBP, akan menjadi data masukan ke sistem klasifikasi *Probabilistic Neural Network* (PNN). PNN dipilih karena kecepatan operasinya dan kehandalannya dalam mengklasifikasi dan mengenali pola (Specht, 1990) (Wang, 2013), dan telah diaplikasikan pada klasifikasi *kansei* pada citra Batik (Nilogiri, 2012).

1.2 Rumusan Masalah

Dalam penelitian ini, masalah yang akan diselesaikan dirumuskan sebagai berikut:

- a. Bagaimana menyisipkan algoritma LBPROT ke dalam algoritma CRLBP?
- b. Bagaimana mengekstraksi ciri tekstur menggunakan ICRLBP?
- c. Bagaimana menyusun histogram yang berisi gabungan dari semua informasi ciri ICRLBP?
- d. Bagaimana membangun sistem klasifikasi menggunakan PNN?
- e. Bagaimana mengevaluasi sistem klasifikasi?

1.3 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

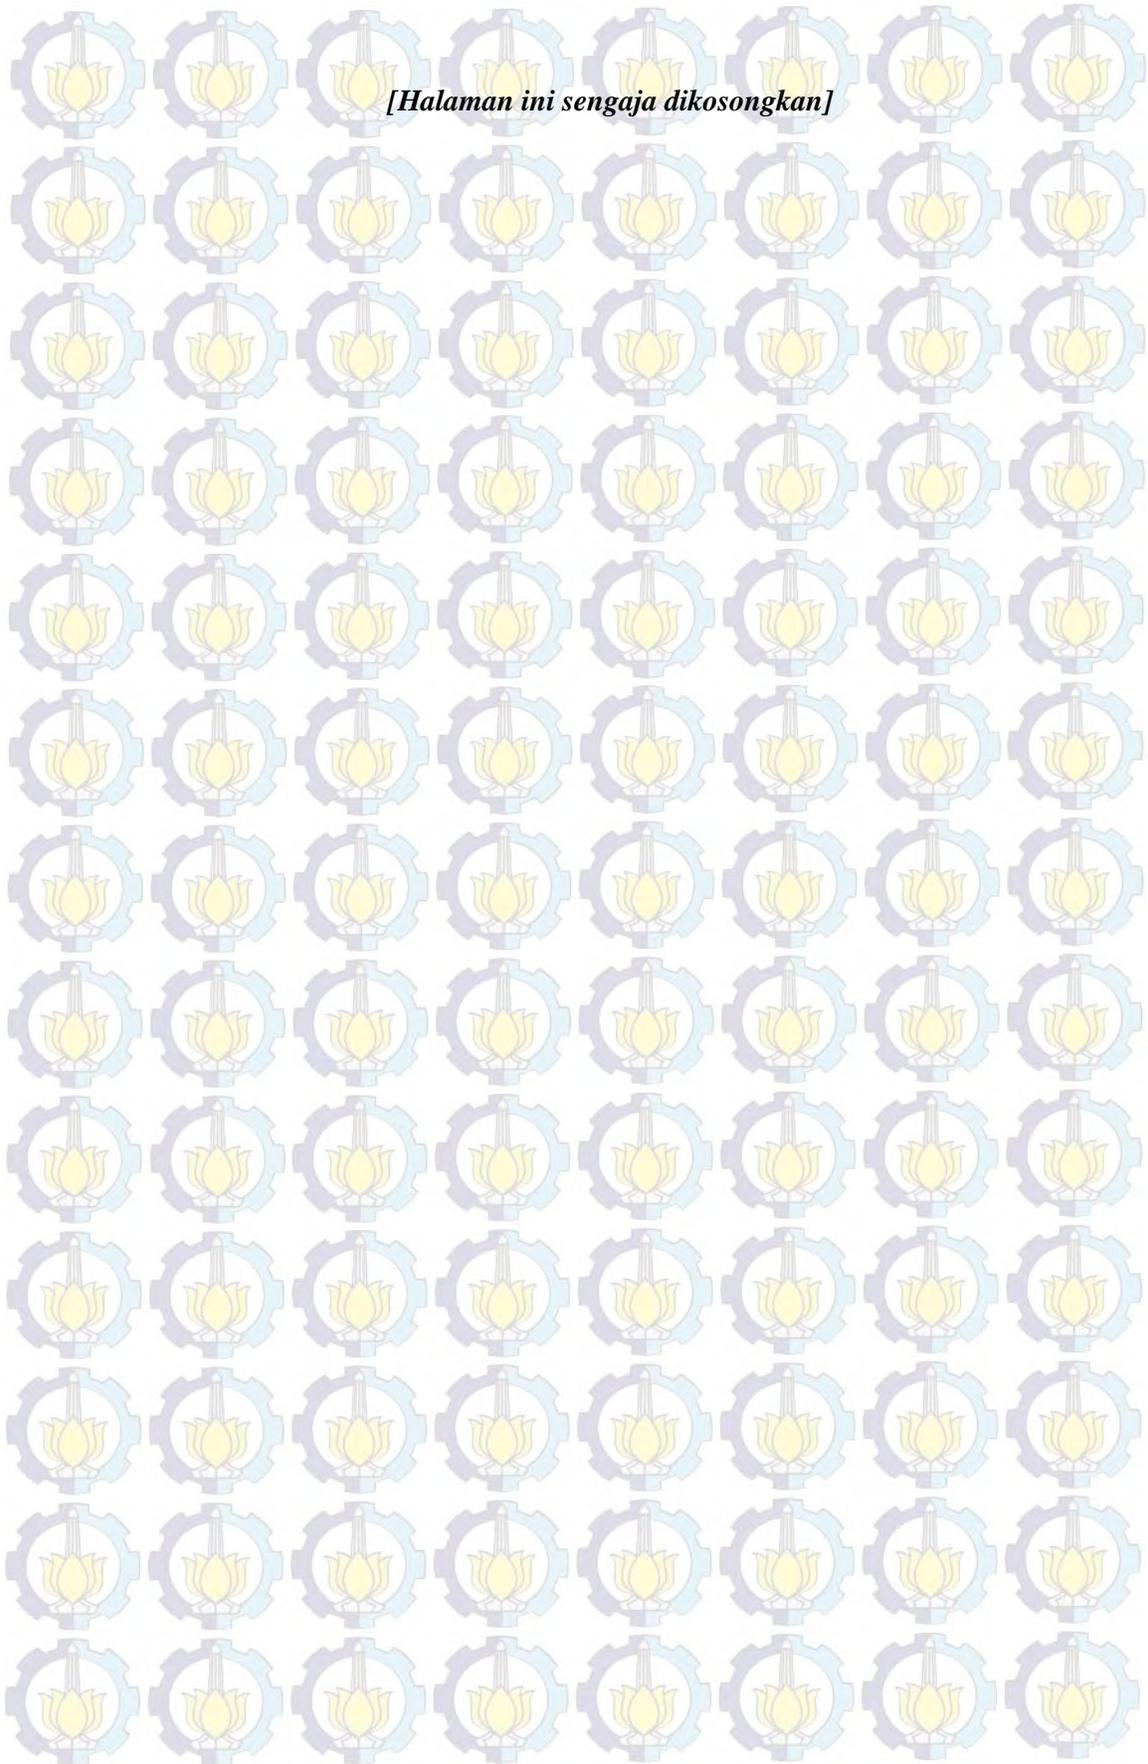
- a. Dataset citra diseragam dengan ukuran 128x128.
- b. Dataset citra dirotasi kelipatan 5° dan 45°, yaitu 5°, 10°, 15°, 20°, 25°, 30°, 35°, 40°, 45°, 50°, 55°, 60°, 75°, 80°, 85°, 90°, 135°, 180°, 225°, 270°, dan 315°.
- c. Citra Batik yang digunakan hanya berisi satu jenis motif dasar dan tidak memiliki pinggiran.
- d. Motif dasar Batik yang diklasifikasi adalah : banji, ceplok, kawung, nitik, tambal, parang, udan liris, semen, dan buketan.

1.4 Tujuan dan Manfaat Penelitian

Penelitian ini bertujuan untuk mengembangkan sebuah sistem visi komputer yang dapat mengekstraksi ciri tekstur Batik dengan baik, menggunakan metode ekstraksi ciri *Improved Completed Robust Local Binary Pattern* dengan metode klasifikasi *Probabilistic Neural Network*. Manfaat penelitian ini menghasilkan sistem klasifikasi motif dasar Batik dengan menggunakan metode ekstraksi ciri *Improved Completed Robust Local Binary Pattern* yang diharapkan dapat mengelompokkan motif dasar Batik secara tepat.

1.5 Kontribusi Penelitian

Kontribusi dalam penelitian ini adalah menyisipkan algoritma LBPROT ke dalam algoritma *Completed Robust Local Binary Pattern*, sehingga dapat menghasilkan metode ekstraksi ciri tekstur yang *invariant* terhadap rotasi dan lebih handal dibandingkan dengan metode *Completed Robust Local Binary Pattern*. Metode ekstraksi ciri tekstur yang diusulkan tersebut selanjutnya disebut *Improved Completed Robust Local Binary Pattern*.



BAB 2

DASAR TEORI DAN KAJIAN PUSTAKA

Bab ini berisi pembahasan tentang kajian pustaka dan dasar-dasar teori yang digunakan dalam membangun sistem klasifikasi Batik. Dasar teori dan kajian pustaka yang dibahas pada bab ini terdiri atas lima subbab. Subbab pertama berisi penjelasan tentang Batik dan penggolongan motifnya, subbab kedua berisi penjelasan tentang *Local Binary Pattern*, subbab ketiga berisi penjelasan tentang *Completed Robust Local Binary Pattern*, subbab keempat berisi penjelasan tentang LBPROT dan subbab kelima berisi penjelasan tentang *Probabilistic Neural Network*.

2.1 Batik

Batik adalah corak atau pola tradisional pada kain yang digambar dengan metode tradisional. Corak pada kain Batik pada umumnya terdiri atas dua bagian (Doellah, 2002) :

- ❖ Klowongan atau pola utama. Pola utama merupakan pola dasar yang kemudian akan membentuk suatu kerangka gambar untuk membentuk Batik secara keseluruhan, atau disebut motif (Susanto, 1980).
- ❖ Isen-isen atau pengisi. Isen-isen merupakan ornamen kecil yang digunakan untuk mengisi atau menghiasi ruang kosong pada pola dasar.

Pada perkembangannya, terdapat banyak variasi corak Batik yang beredar di masyarakat. Oleh karena itu, untuk memudahkan pengelompokan Batik maka Batik dideskripsikan berdasarkan motif dasarnya.

2.1.1 Penggolongan Motif Batik

Pola-pola dasar Batik disusun secara berulang untuk menggambarkan motif dasar pada suatu kain secara keseluruhan. Keberulangan motif pada suatu kain Batik dapat disusun baik secara teratur maupun tidak teratur (Haake, 1989). Oleh karena itu, Batik klasik dapat dikelompokkan menjadi dua kelas utama berdasarkan sifat keberulangannya, yaitu geometri dan non-geometri (Doellah,

2002) (Susanto, 1980). Selanjutnya, masing-masing dari kelas utama tersebut dibagi lagi menjadi beberapa subkelas. Berikut ini penjelasan tentang pembagian jenis motif tersebut:

a. Motif geometris

Motif geometris adalah motif Batik yang pola dasarnya membentuk bangun geometris tertentu secara berulang dan beraturan. Pada umumnya motif ini merupakan Batik cap. Motif geometris dapat dibagi lagi menjadi beberapa subkelas (Haake, 1989) :

❖ Banji.

Motif dasarnya berdasarkan *swastika*. Disusun dari garis yang saling berpotongan tegak lurus dengan panjang yang sama. Contoh motif banji ditunjukkan pada Gambar 2.1 (a).

❖ Stensil.

Pola yang diadaptasi dari karakter bunga atau buah. Motif ini dapat dibagi lagi yaitu : ceplik, kawung, dan ganggong. Pada umumnya ceplik terdiri dari garis-garis yang membentuk persegi, lingkaran, atau jajargenjang. Kemudian diantara garis-garis tersebut berisi bunga. Kawung yang berarti buah aren atau kolang-kaling, membentuk pola lingkaran yang saling berpotongan. Ganggong merupakan pola khusus dari ceplik berdasarkan pada karakter tanaman air ganggong. Contoh motif stensil ditunjukkan pada Gambar 2.1 (b) untuk ceplik, Gambar 2.1 (c) motif kawung, sedangkan Gambar 2.1 (d) motif ganggong.

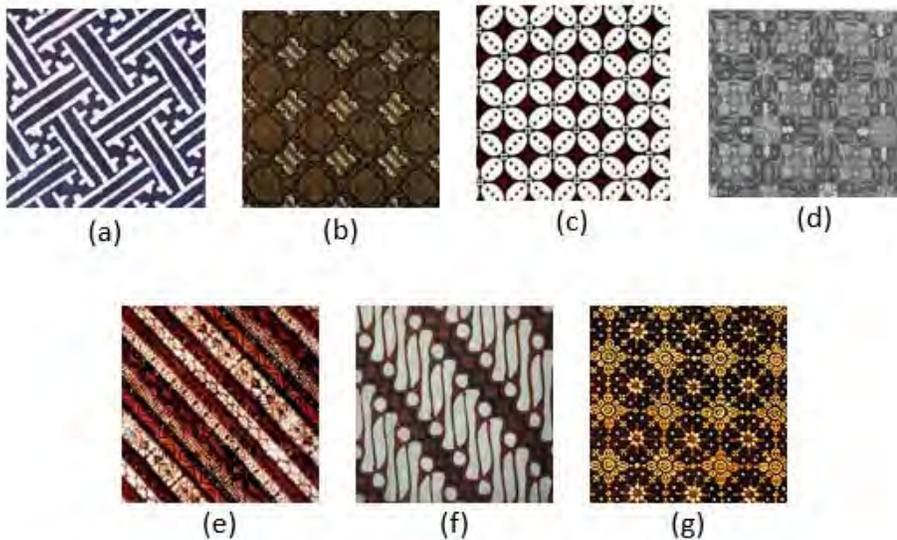
❖ Garis miring.

Motif dasarnya adalah garis-garis diagonal yang saling sejajar. Motif ini dapat dibagi lagi yaitu : udan liris dan parang. Udan liris tersusun atas garis-garis diagonal yang menyerupai hujan rintik-rintik. Pada motif Parang, diantara garis diagonal dipisahkan dengan deretan ornamen *mlinjon* dan terdapat garis-garis pengisi yang tegak lurus diagonal. Contoh motif garis

miring ditunjukkan pada Gambar 2.1 (e) untuk udan liris, Gambar 2.1 (f) motif parang.

❖ Anyaman atau nitik.

Pola ini berupa susunan titik atau garis putus-putus membentuk pola anyaman atau tenunan. Susunan titik-titik atau garis putus-putus pada umumnya membentuk ornamen menyerupai ceplok atau lereng. Contoh motif nitik ditunjukkan pada Gambar 2.1 (g).



Gambar 2.1 Motif Batik Geometri. (a) Banjir. (b) Ceplok. (c) Kawung. (d) Ganggong. (e) Udan Liris. (f) Parang. (g) Nitik.

b. Motif non-geometris

Motif non-geometris adalah motif Batik yang motif dasarnya tidak mengalami perulangan atau motif dasarnya mengalami perulangan namun tidak beraturan. Pada umumnya motif ini merupakan Batik tulis. Motif non-geometris dapat dibagi lagi menjadi beberapa subkelas (Haake, 1989) :

❖ Semen.

Motif dasar semen adalah terdapat gambar meru atau gunung. Kemudian ada yang ditambah ornament umbuh-tumbuhan, binatang, dan binatang bersayap. Contoh motif semen ditunjukkan pada Gambar 2.2 (a).

❖ Buketan.

Buketan merupakan bahasa serapan *bouquet* atau berarti karangan bunga. Sehingga gambar bunga akan mendominasi motif ini. Contoh motif semen ditunjukkan pada Gambar 2.2 (b).



Gambar 2.2 Motif Batik Non-Geometri. (a) Semen. (b) Buketan.

Selain kelas geometri dan non-geomeris, motif Batik juga dapat dikelompokkan pada kelas *samplers*. Pada kelas motif Batik tersebut, pada satu kain berisi motif gabungan antara motif geometris dan non-geometris. Motif *sampler* dapat dibagi lagi menjadi beberapa subkelas (Haake, 1989) :

❖ Tambal. Contoh motif tambal ditunjukkan pada Gambar 2.3 (a).

❖ *Compotition*. Contoh motif *compotition* ditunjukkan pada Gambar 2.3 (b).



Gambar 2.3 Motif Batik *Sampler*. (a) Tambal. (b) *Composition*.

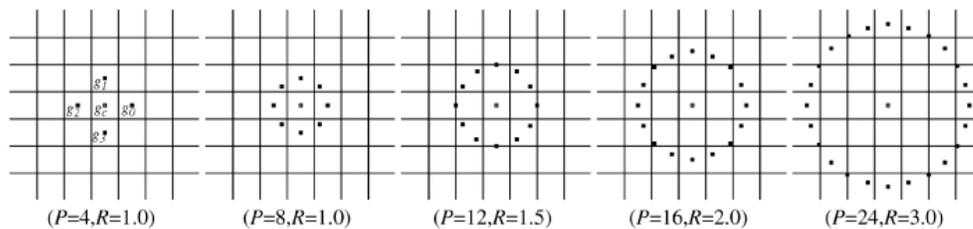
2.2 *Local Binary Pattern*

Local Binary Pattern (LBP) adalah metode analisis tekstur yang menggunakan model statistika dan struktur. LBP menganalisis tekstur secara lokal pada domain *spatial*, dengan membandingkan intensitas piksel antara piksel pusat

dengan piksel-piksel tetangganya pada radius tertentu. Sehingga informasi gradien dapat diperoleh untuk merepresentasikan tepi, titik, dan ciri lokal lainnya dari suatu citra. Selanjutnya suatu histogram disusun untuk mengetahui distribusi nilai gradien. Dengan metode perhitungan yang sederhana tersebut, menjadikan LBP cukup handal pada citra yang memiliki perbedaan pencahayaan.

LBP telah diusulkan untuk mengklasifikasi data tekstur Outex dan Brodatz. Dari penelitian tersebut LBP memberikan hasil yang memuaskan dimana dapat mengklafikasi lebih baik dari metode *Wavelet-Based Rotation Invariant Features*, pada data yang memiliki perbedaan pencahayaan (Ojala, 2002). Langkah-langkah LBP dalam mengekstraksi ciri adalah :

1. Pada setiap piksel, dihitung nilai LBP dengan membandingkan intensitas piksel antara intensitas piksel pusat dengan intensitas piksel-piksel tetangganya pada radius tertentu, seperti yang ditunjukkan pada Gambar 2.4. Intensitas piksel pusat menjadi *thresholding* untuk menyusun nilai LBP di setiap piksel citra.



Gambar 2.4 Operator LBP

2. Bila nilai intensitas piksel pusat lebih besar dibandingkan nilai intensitas piksel tetangganya maka nilai transformasi biner untuk piksel pusat adalah satu. Sebaliknya, bila nilai intensitas piksel pusat lebih kecil dibandingkan nilai intensitas piksel tetangganya maka nilai transformasi biner untuk piksel pusat adalah nol, seperti yang ditunjukkan pada Gambar 2.5(b).
3. Nilai biner dari piksel tetangga tersebut disusun, seperti yang ditunjukkan pada Gambar 2.5(c).

4. Susunan nilai biner tersebut dikonversi ke nilai desimal, dengan cara mengalikan nilai biner dengan bobotnya, seperti yang ditunjukkan pada Gambar 2.5(c) dan Gambar 2.5(d).

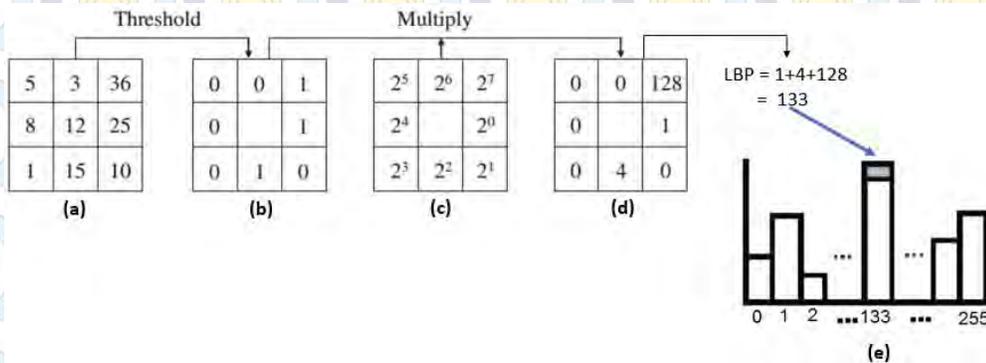
5. Secara matematika, perhitungan LBP dapat ditulis berdasarkan Persamaan (2.1).

$$LBP_{p,R} = \sum_{p=0}^{P-1} s(I_{p,R} - I_c) 2^{P-1-p} \quad (2.1)$$

Dimana,

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.2)$$

P adalah jumlah banyaknya tetangga, R adalah radius antara titik pusat dan titik tetangga, $LBP_{p,R}$ adalah nilai desimal hasil konversi nilai biner, I_c adalah nilai intensitas piksel pusat, $I_{p,R}$ adalah nilai intensitas piksel tetangga ke- p ($p = 0, 1, \dots, P - 1$) dengan radius R . Sedangkan $s(x)$ adalah fungsi *thresholding*.



Gambar 2.5 Ilustrasi Proses LBP. (a) Citra asli. (b) Hasil perbandingan dengan fungsi *thresholding*. (c) Bobot. (d) Hasil perkalian dengan bobot. (e) Histogram ciri LBP.

6. Histogram disusun, seperti yang ditunjukkan pada Gambar 2.5(e). Secara matematika, histogram dapat didefinisikan dengan Persamaan (2.3).

$$H_j = \sum_{x,y} I(x,y) = j, \quad j = 0, 1, \dots, n - 1 \quad (2.3)$$

H_j adalah nilai histogram pada intensitas ke- j , $I(x, y)$ adalah nilai intensitas pada koordinat piksel (x, y) , L adalah ukuran jumlah piksel pada suatu citra, dan n adalah nilai maksimal intensitas.

2.3 Completed Robust Local Binary Pattern

Completed Robust Local Binary Pattern (CRLBP) merupakan perkembangan dari metode *Completed Local Binary Pattern* (CLBP), sehingga CRLBP memiliki ide dasar yang sama dengan CLBP dalam mengekstraksi ciri tekstur. Ide dasarnya yaitu tekstur digambarkan secara lokal berdasarkan intensitas piksel pusat serta perbedaan *sign* dan *magnitude* intensitas dari piksel tetangga terhadap intensitas piksel pusat (perbedaan lokal). *Sign* merupakan representasi nilai yang menunjukkan apakah intensitas piksel tetangga lebih kecil atau lebih besar dari intensitas piksel pusat. Jika intensitas piksel tetangga lebih kecil dari intensitas piksel pusat maka nilai *sign* adalah 0, sebaliknya jika intensitas piksel tetangga lebih besar dari intensitas piksel pusat maka nilai *sign* adalah 1. Seperti yang ditunjukkan pada Persamaan (2.2). Sedangkan *magnitude* merupakan representasi besarnya nilai perbedaan antara intensitas piksel tetangga dengan intensitas piksel pusat.

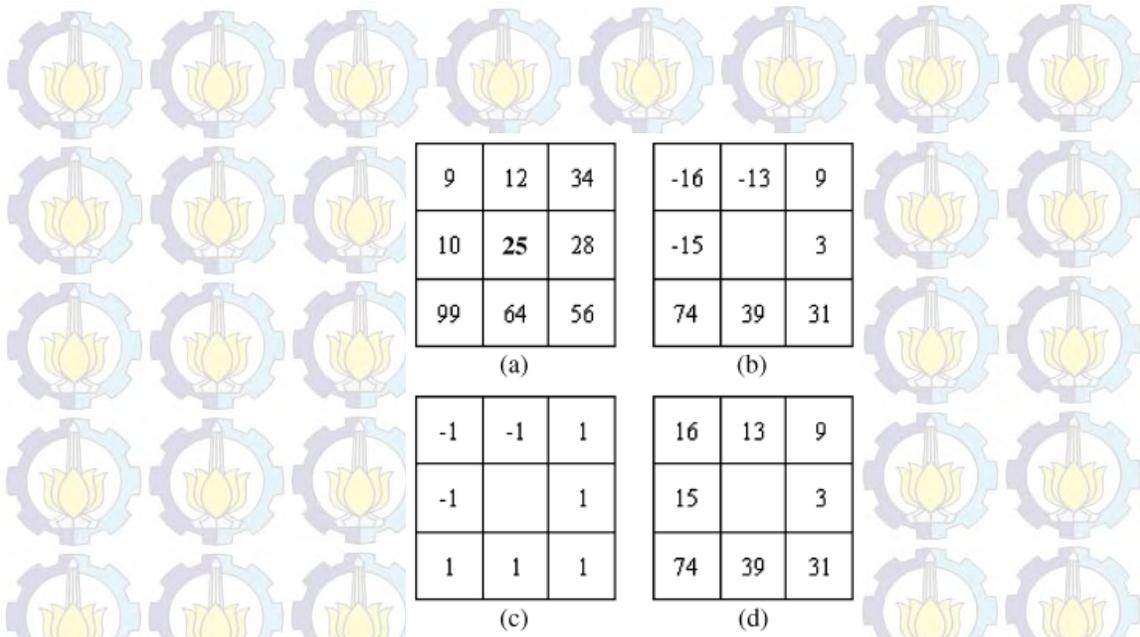
Perbedaan lokal dapat dirumuskan seperti Persamaan (2.4), dimana $s_{p,R}$ adalah *sign*, $m_{p,R}$ adalah *magnitude*, $s(x)$, I_c , $I_{p,R}$, P , dan R telah dijelaskan pada Persamaan (2.1).

$$d_{p,R} = s_{p,R} * m_{p,R}, \quad \begin{cases} s_{p,R} = \text{sign}(d_{p,R}) \\ m_{p,R} = |d_{p,R}| \end{cases} \quad (2.4)$$

Dimana,

$$s_{p,R} = s(I_{p,R} - I_c) \quad \text{dan} \quad m_{p,R} = |I_{p,R} - I_c| \quad (2.5)$$

Kemudian $s_{p,R}$ disusun menjadi *sign vector* $[s_0, s_1, \dots, s_{P-1}]$, dan $m_{p,R}$ disusun menjadi *magnitude vector* $[m_0, m_1, \dots, m_{P-1}]$. Ilustrasinya ditunjukkan pada Gambar 2.6 Dari tersebut diperoleh *difference vector* nya adalah $[3, 9, -13, -16, -15, 74, 39, 31]$, sedangkan *sign vector* adalah $[1, 1, -1, -1, -1, 1, 1, 1]$ dan *magnitude vector* adalah $[3, 9, 13, 16, 15, 74, 39, 31]$



Gambar 2.6 Ilustrasi Proses CLBP. (a) Citra asli. (b) Perbedaan lokal ($d_{p,R}$). (c) *Sign vector*. (d) *Magnitude vector*.

Setelah *sign vector* dan *magnitude vector* diperoleh, nilai vektor tersebut ditransformasi menggunakan operator CLBP_S untuk *sign vector* dan CLBP_M untuk *magnitude vector*.

Perbedaan antara CLBP dan CRLBP adalah pada nilai *thresholding*. Pada CLBP nilai *thresholding* adalah intensitas piksel pusat, sedangkan pada CRLBP dihitung menggunakan *Weighted Local Gray Level (WLG)* atau Persamaan (2.6).

$$WLG = \frac{\sum_{p=0}^{P-1} I_{p,R} + \alpha I_c}{P + \alpha} \quad (2.6)$$

Dimana α adalah nilai parameter yang ditentukan oleh *user*, I_c , $I_{p,R}$, P , dan R telah dijelaskan pada Persamaan (2.1).

Sehingga diperoleh operator CRLBP_S seperti pada Persamaan (2.7)

$$\begin{aligned} CRLBP_S &= \sum_{p=0}^{P-1} s(I_{p,R} - WLG_c) 2^{P-1-p} \\ &= \sum_{p=0}^{P-1} s\left(I_{p,R} - \frac{\sum_{i=0}^{P-1} I_{ci,R} + \alpha I_c}{P + \alpha}\right) \end{aligned} \quad (2.7)$$

Dimana $I_{ci,R}$ adalah intensitas piksel tetangga ke- i ($i = 0, 1, \dots, P - 1$) dengan radius R dari piksel pusat I_c , $s(x)$, I_c , $I_{p,R}$, P , dan R telah dijelaskan pada Persamaan (2.1), α telah dijelaskan pada Persamaan (2.6).

Sedangkan operator CRLBP_M ditunjukkan pada Persamaan (2.8).

$$CRLBP_M = \sum_{p=0}^{P-1} s(m_p - c) 2^{P-1-p} \quad (2.8)$$

Dimana,

$$m_p = \left| WLG_p - WLG_c \right| \\ = \left| \frac{\sum_{i=0}^{P-1} I_{pi,R} + \alpha I_{p,R}}{P + \alpha} - \frac{\sum_{i=0}^{P-1} I_{ci,R} + \alpha I_c}{P + \alpha} \right| \quad (2.9)$$

P , $I_{ci,R}$, I_c , $I_{p,R}$, dan R telah dijelaskan pada Persamaan (2.7), sedangkan $I_{pi,R}$ adalah intensitas piksel tetangga ke- i ($i = 0, 1, \dots, P - 1$) dengan radius R dari piksel pusat $I_{p,R}$. Sedangkan c adalah *threshold* yang diperoleh dari nilai rata-rata m_p dari seluruh citra. CRLBP_M menghitung nilai varians lokal dari WLG.

Intensitas piksel pusat digambarkan dengan operator CRLBP_C, seperti ditunjukkan pada Persamaan (2.10).

$$CRLBP_C = s(WLG_c - c_l) \quad (2.10)$$

Dimana c_l adalah *threshold* yang diperoleh dari nilai rata-rata *Average Local Gray Level* (ALG) dari seluruh citra. ALG dihitung dengan Persamaan (2.11).

$$ALG = \frac{\sum_{p=0}^{P-1} I_{p,R} + I_c}{P} \quad (2.11)$$

Pada citra *grayscale* dengan operator LBP P sama dengan 8, maka diperoleh 256 ciri dari histogram CRLBP_S, 256 ciri dari histogram CRLBP_M, dan 2 ciri dari histogram CRLBP_C.

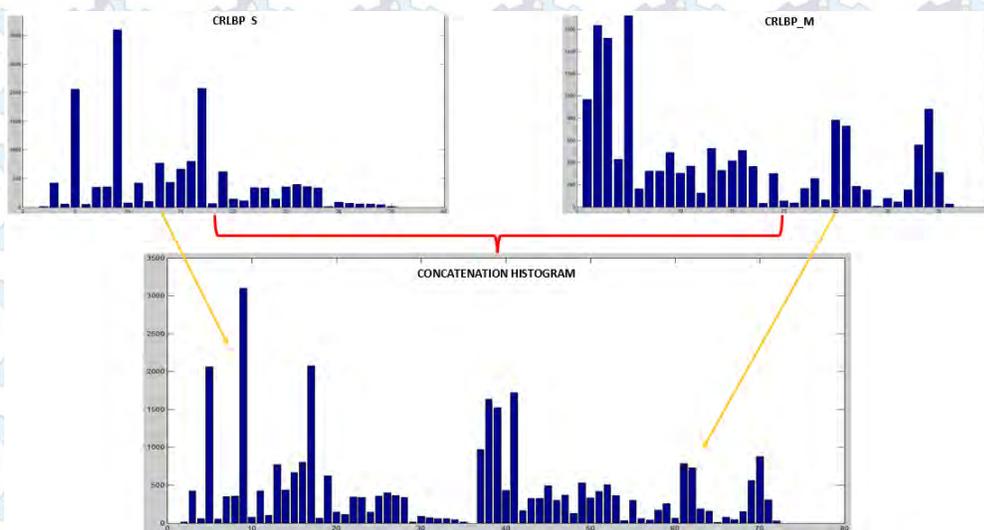
Ketiga ciri, CRLBP_S, CRLBP_M, dan CRLBP_C memiliki format yang sama yaitu *binary*, sehingga dapat dengan mudah digabungkan untuk membentuk histogram akhir CRLBP.

2.4 Penggabungan histogram

Dari bab sebelumnya, diketahui ada 3 macam histogram ciri hasil ekstraksi ciri CRLBP, yaitu histogram ciri CRLBP_S, histogram ciri CRLBP_M, dan histogram ciri CRLBP_C. Menurut Guo pada CLBP (Guo, 2010), ada dua macam cara yang digunakan untuk menggabungkan ketiga histogram ciri tersebut untuk membentuk histogram akhir CRLBP, yaitu *concatenation* atau *jointly*.

2.4.1 Concatenation

Concatenation adalah penggabungan histogram dengan cara merangkai atau jalin-menjalin dari satu histogram dengan histogram lainnya. Sebagai contoh ditunjukkan pada Gambar 2.7.



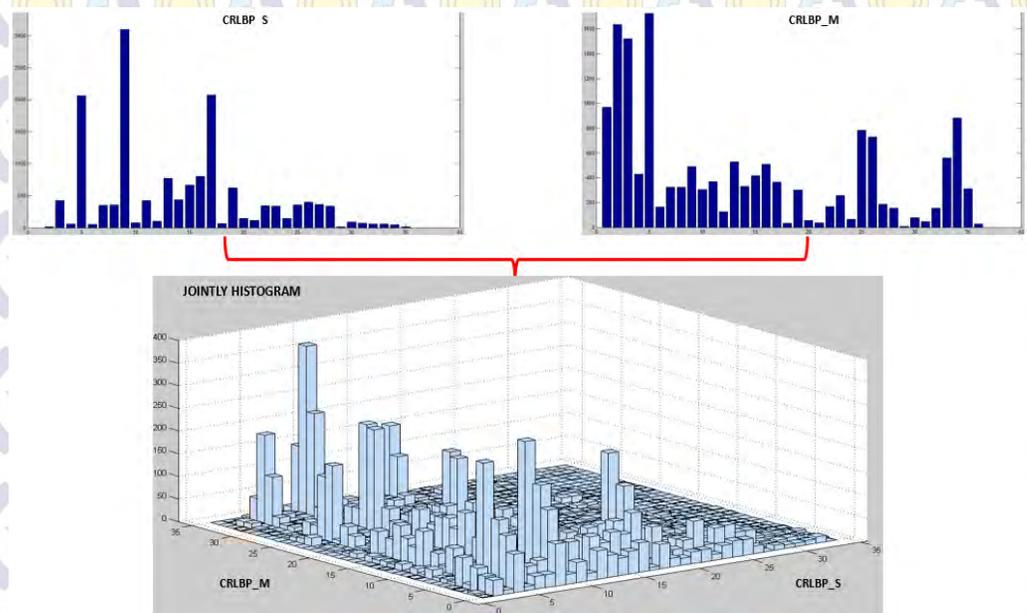
Gambar 2.7 Concatenation histogram.

Pada Gambar 2.7 terdapat dua histogram ciri yang akan digabung secara *concatenation* yaitu, CRLBP_S dan CRLBP_M. CRLBP_S memiliki 36 ciri dalam satu histogram, begitu pula pada CRLBP_M memiliki 36 ciri dalam satu histogram. Histogram CRLBP_S dan histogram CRLBP_M digabung dengan cara *concatenation*, yaitu histogram CRLBP_M digambarkan setelah histogram CRLBP_S. Sehingga diperoleh histogram akhir yang merupakan gabungan antara histogram CRLBP_S dan histogram CRLBP_M. Histogram akhir memiliki 72 ciri

yang berasal dari 32 ciri histogram CRLBP_S ditambah dengan 32 ciri histogram CRLBP_M.

2.4.2 Jointly

Jointly adalah penggabungan histogram dengan mencari nilai keterjadian ciri bersama (*co-occurrence*) antara satu histogram dengan histogram lainnya. Sebagai contoh ditunjukkan pada Gambar 2.8.



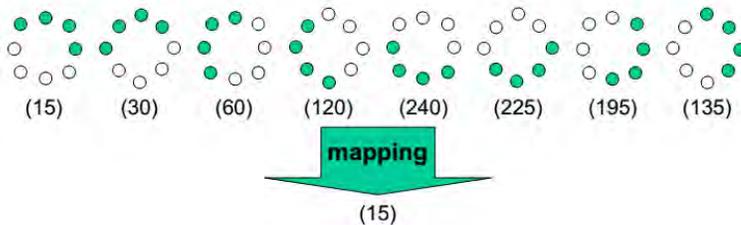
Gambar 2.8 *Jointly* histogram.

Pada Gambar 2.8 terdapat dua histogram ciri yang akan digabung secara *jointly* yaitu, CRLBP_S dan CRLBP_M. CRLBP_S memiliki 36 ciri dalam satu histogram, begitu pula pada CRLBP_M memiliki 36 ciri dalam satu histogram. Histogram CRLBP_S dan histogram CRLBP_M digabung dengan cara *jointly*, yaitu dengan mencari nilai keterjadian ciri bersama (*co-occurrence*) disetiap titik yang sama antara histogram CRLBP_S dengan histogram CRLBP_M. Sehingga diperoleh histogram akhir yang merupakan gabungan antara histogram CRLBP_S dan histogram CRLBP_M. Histogram akhir memiliki 1296 ciri yang berasal dari 32 ciri histogram CRLBP_S dikali dengan 32 ciri histogram CRLBP_M.

2.5 LBP yang *invariant* terhadap rotasi

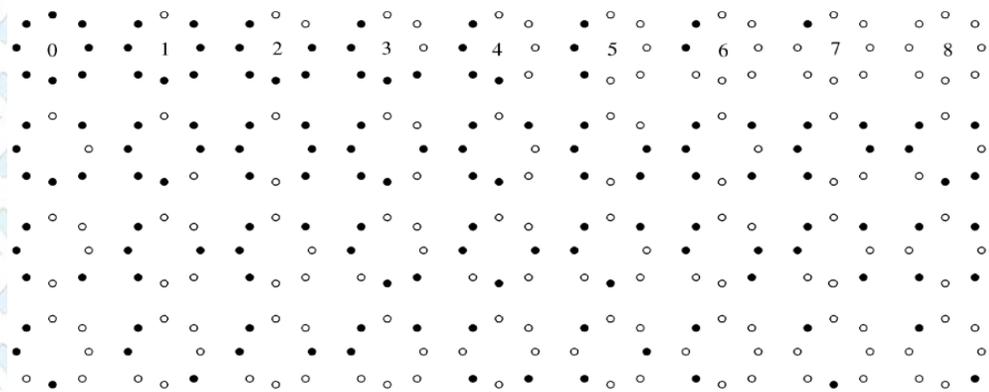
LBP yang *invariant* terhadap rotasi (LBPROT) mengekstraksi ciri tekstur seperti yang ditunjukkan pada Gambar 2.9. Nilai biner yang diperoleh dari hasil ekstraksi ciri tekstur LBP sebelum diubah ke nilai desimal, digeser hingga diperoleh nilai biner yang paling kecil. LBPROT dapat ditulis dengan Persamaan (2.12).

$$LBPROT_{P,R} = LBP_{P,R}^{ri} = \min \{ROR(LBP_{P,R}, p)\} \quad (2.12)$$



Gambar 2.9 Penggeseran nilai biner untuk mencari kombinasi nilai terkecil.

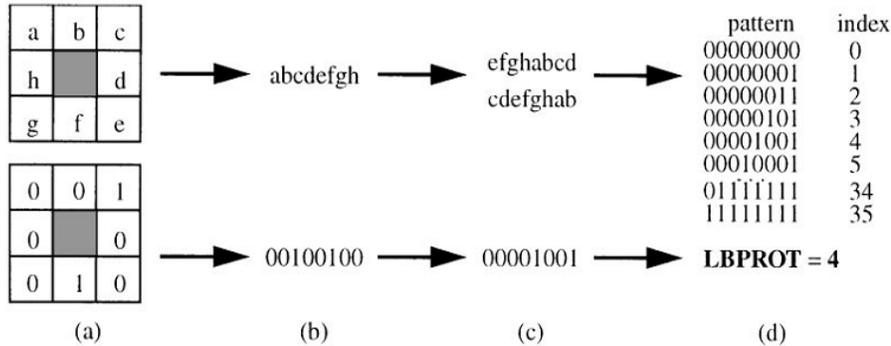
Selain itu, dapat juga menggunakan sistem pengindeksan. Misal, P sama dengan 8 maka LBPROT memiliki 36 pola dasar seperti yang ditunjukkan pada Gambar 2.10.



Gambar 2.10 Ilustrasi 36 pola dasar LBPROT

Sehingga, dapat dilakukan pengindeksaan seperti Gambar 2.11 Nilai biner yang diperoleh dari hasil ekstraksi ciri tekstur LBP sebelum diubah ke nilai

desimal, digeser hingga polanya cocok dengan salah satu pola dari 36 indeks tersebut. Nilai indeks tersebut yang akan menjadi nilai ciri LBPROT.



Gambar 2.11 Proses LBPROT dengan cara pengindeksan.

2.6 Probabilistic Neural Network

Probabilistic neural network (PNN) merupakan salah satu metode klasifikasi Jaringan Syaraf Tiruan berdasarkan metode *feedforward* (Timung, 2013). Ide dasar dari PNN diadopsi dari prinsip Bayes-Parzen dari statistika (Timung, 2013) (Wang, 2013). Arsitektur PNN tersusun atas empat lapisan, yaitu *input layer*, *pattern layer*, *summation layer*, dan *decision layer*. Arsitektur PNN ditunjukkan pada Gambar 2.12.

2.6.1 Input Layer

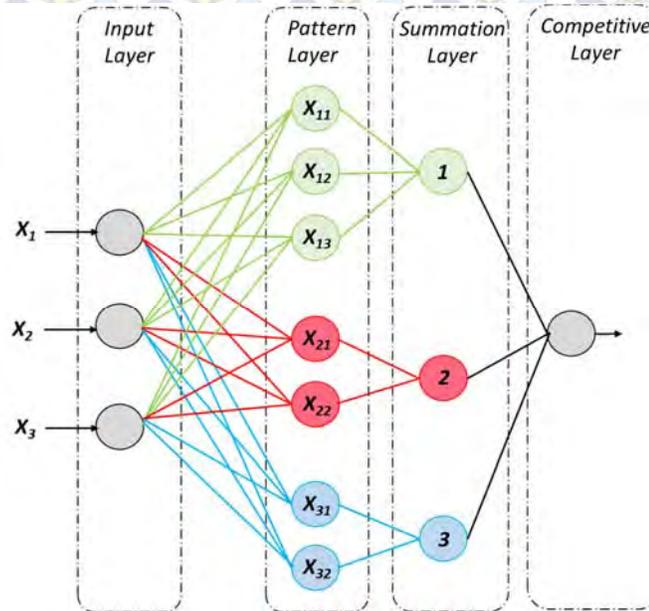
Input layer terdiri atas *node-node* masukkan dari vektor ciri. Sehingga, pada *input layer* tidak ada operasi perhitungan. Vektor ciri adalah dimensi atau banyaknya ciri dalam satu data citra.

2.6.2 Pattern Layer

Pattern layer dibagi berdasarkan jumlah kelasnya, seperti ditunjukkan pada Gambar 2.12, terdapat 3 kelas yaitu kuning, merah, dan biru. Pada masing-masing kelas terdiri atas *neuron-neuron* yang jumlahnya sama dengan jumlah dari data latih. Pada *pattern layer*, data masukkan dihitung menggunakan fungsi *multi-dimensional* Gaussian dengan *probability density function* (PDF) berdasarkan Parzen widow, seperti yang ditunjukkan pada Persamaan (2.13).

$$\varphi_{ki}(x) = \frac{1}{\sqrt{(2\pi)^d \cdot \sigma^d}} \exp\left(-\frac{\|x_i - x_{ki}\|^2}{2\sigma^2}\right) \quad (2.13)$$

Dimana x_i adalah vektor ciri, x_{ki} adalah data latih, k menunjukkan kelas dari data latih, d menunjukkan dimensi atau banyaknya jumlah ciri, dan σ adalah *smoothing parameters*.



Gambar 2.12 Arsitektur PNN.

2.6.3 Summation Layer

Summation layer menghitung penjumlahan dan nilai rata-rata dari keluaran *pattern layer* dari masing-masing kelas, menggunakan Persamaan (2.14).

$$g_k(x) = \frac{1}{\sqrt{(2\pi)^d}} \cdot \frac{1}{n\sigma^d} \sum_{i=1}^n \exp\left(-\frac{\|x_i - x_{ki}\|^2}{2\sigma^2}\right) \quad (2.14)$$

Dimana n adalah jumlah dari data latih.

Summation layer secara tidak langsung menghitung *maximum likelihood* dari vektor ciri.

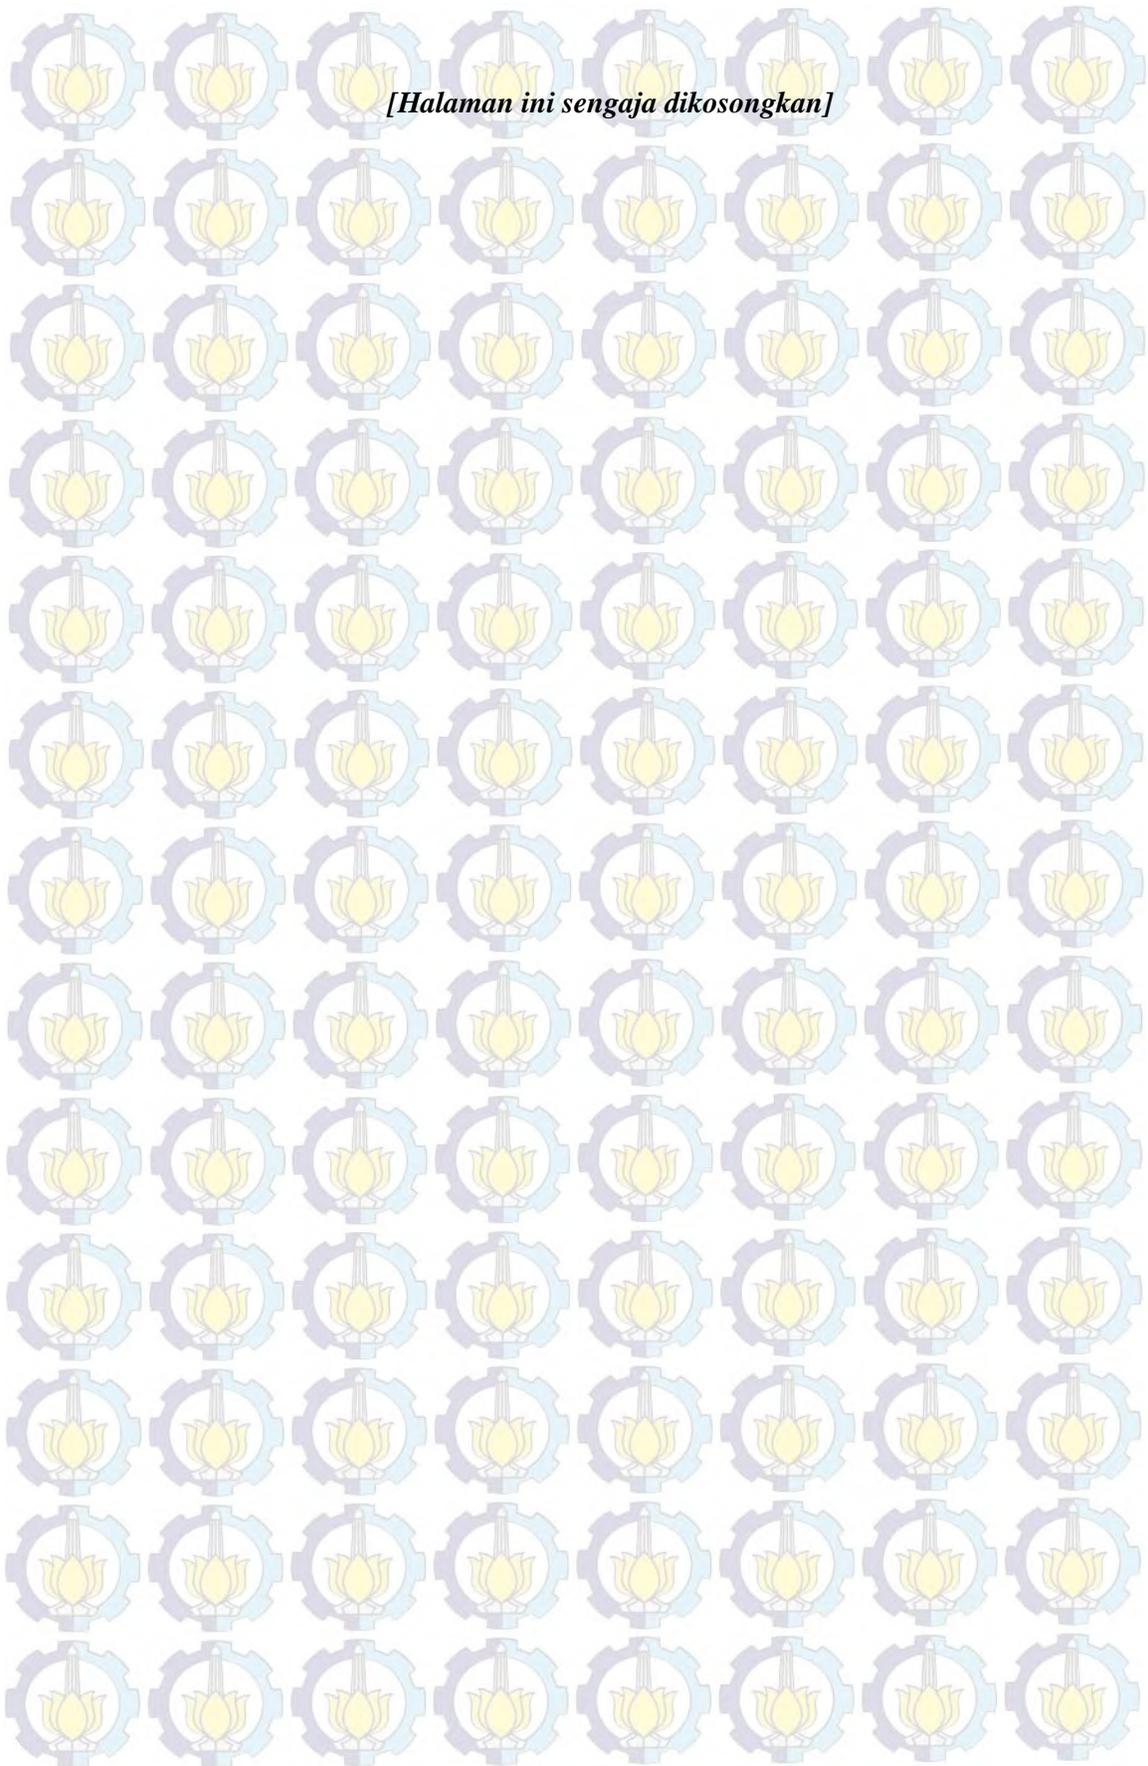
2.6.4 Competitive Layer

Competitive layer melakukan perbandingan nilai hasil keluaran *summation layer* dari masing-masing kelas, dengan Persamaan (2.15). Kemudian

memberikan nilai 1 pada kelas mana yang memiliki nilai *maximum probabilities*, dan memberikan 0 pada kelas yang lain.

$$C(x) = \arg \max\{g_k(x)\}, k = 1, 2, \dots, m \quad (2.15)$$

Dimana m adalah jumlah kelas.



BAB 3

METODE PENELITIAN

3.1 Rancangan Penelitian

Penelitian ini dikerjakan dalam empat tahapan yaitu studi literatur, analisa dan perancangan algoritma, implementasi algoritma, serta uji coba dan analisa hasil uji coba. Adapun penjelasan tentang masing-masing tahapan tersebut adalah sebagai berikut:

1. Studi literatur

Studi literatur ditujukan untuk mencari referensi-referensi yang sesuai dengan penelitian ini. Referensi dapat berupa jurnal, buku, makalah ilmiah, serta hasil wawancara dengan narasumber yang ahli di bidang penggolongan motif Batik. Informasi dari referensi selanjutnya digunakan untuk mendefinisikan rumusan permasalahan, batasan permasalahan, kebutuhan dataset serta kontribusi yang akan diusulkan.

2. Analisa dan Perancangan Algoritma

Tahap ini bertujuan untuk menghasilkan rancangan algoritma yang akan dijadikan solusi untuk meningkatkan akurasi sistem dalam mengklasifikasikan motif Batik. Ide dasar dari algoritma yang akan diusulkan dalam penelitian ini berangkat dari algoritma LBP dengan pengembangan pada penambahan ciri pada histogram. Luaran dari tahap ini adalah rancangan algoritma beserta penjelasannya yang tersaji dalam bentuk diagram alir ataupun *pseudocode*.

3. Implementasi Algoritma

Tahap ini bertujuan untuk mengimplementasikan algoritma yang sudah dirancang pada tahap sebelumnya. Dalam penelitian ini, rancangan algoritma diimplementasikan menggunakan MATLAB. Luaran yang diharapkan pada tahap ini adalah perangkat lunak yang siap untuk digunakan pada tahap uji coba.

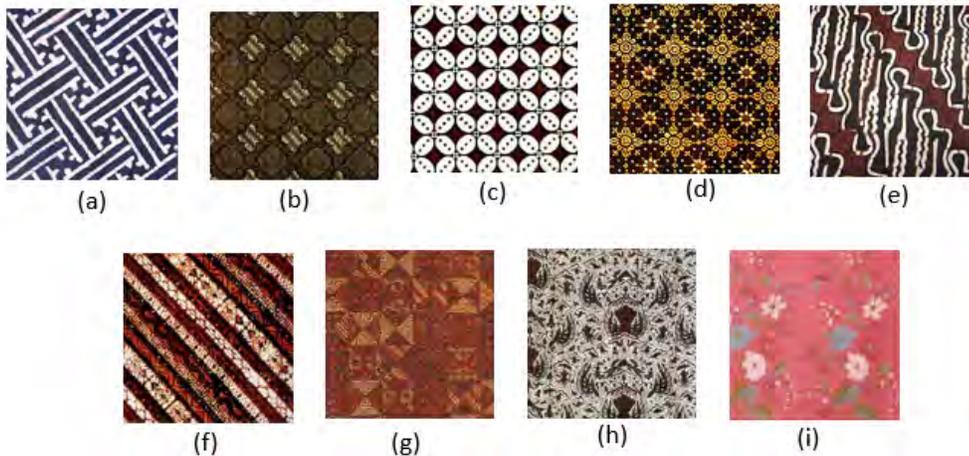
4. Uji Coba dan Analisa Hasil Uji Coba

Pada tahap ini akan dilakukan perancangan skenario uji coba, pelaksanaan uji coba serta analisa hasil uji coba. Skenario uji coba digunakan sebagai panduan uji coba terhadap algoritma yang telah diimplementasikan untuk

mengetahui seberapa optimal kinerja sistem dalam mengklasifikasi motif Batik. Luaran yang diharapkan dari tahap ini adalah analisa hasil ujicoba yang dapat dilaporkan sebagai kesimpulan dari penelitian ini.

3.2 Analisis Data

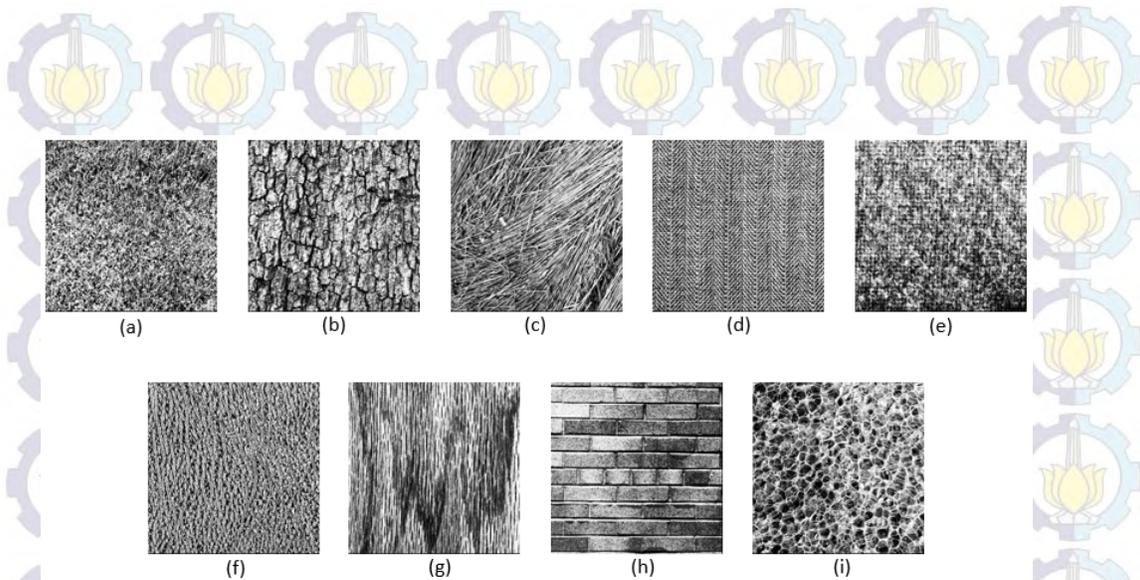
Data yang digunakan untuk menguji kinerja metode ekstraksi ciri yang diusulkan adalah citra Batik. Citra Batik diperoleh dari buku “Batik : Pengaruh Zaman dan Lingkungan” dan dari *browsing* di internet. Citra Batik tersebut dikelompokkan menjadi 9 kelas motif dasar Batik, yaitu banji, ceplok, kawung, tambal, parang, udan liris, semen, dan buketan.



Gambar 3.1 Data Batik. (a) Banji. (b) Ceplok. (c) Kawung. (d) Nitik. (e) Parang. (f) Udan Liris. (g) Tambal. (h) Semen. (i) Buketan.

Selain citra Batik, data Brodatz juga digunakan pada pengujian, karena data Brodatz merupakan data tekstur yang sudah umum digunakan oleh sebagian besar penelitian pada kasus ekstraksi ciri tekstur (Sipi, 2014). Data Brodatz yang digunakan terdiri dari 9 kelas, yaitu Grass (D9), Bark (D12), Straw (D15), Herringbone weave (D16), woolen cloth (D19), Pressed calf leather (D24), Wood grain (D68), Brick wall (D94), dan Plastic bubbles (D112).

Ukuran citra Batik dan citra Brodatz diseragam dengan dimensi 128x128 piksel. Citra Batik yang digunakan ditunjukkan pada Gambar 3.1. Citra Brodatz yang digunakan ditunjukkan pada Gambar 3.2.



Gambar 3.2 Data Brodatz. (a) Grass-D9. (b) Bark-D12. (c) Straw-D15. (d) Herringbone weave-D16. (e) woolen cloth-D19. (f) Pressed calf leather-D24. (g) Wood grain-D68. (h) Brick wall-D94. (i) Plastic bubbles-D112.

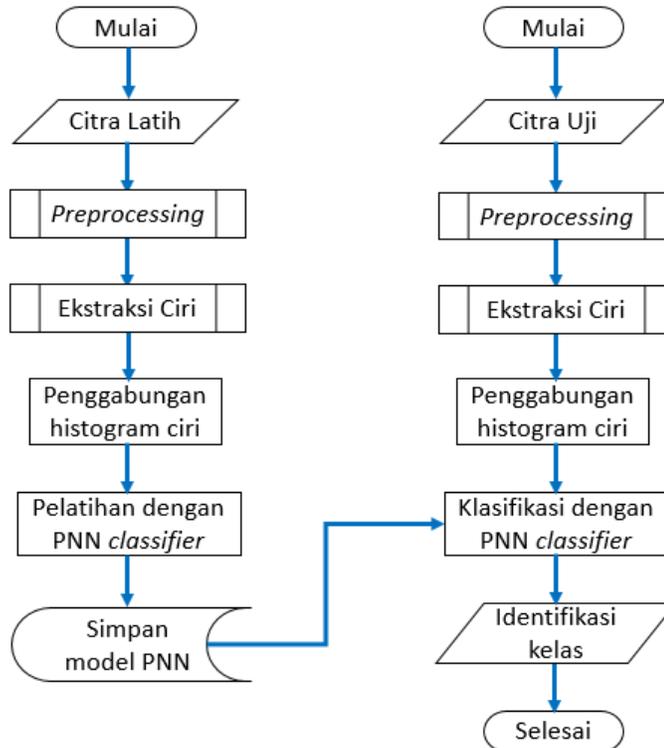
3.3 Improved Completed Robust Local Binary Pattern

Improved Completed Robust Local Binary Pattern (ICRLBP) merupakan metode yang berusaha meningkatkan kinerja CRLBP, agar *invariant* terhadap rotasi. Oleh karena LBPROT merupakan perkembangan dari LBP yang *invariant* terhadap rotasi. Maka, algoritma LBPROT akan disisipkan pada algoritma CRLBP, sehingga menjadi algoritma yang bernama ICRLBP.

Secara keseluruhan ilustrasi diagram alir untuk sistem klasifikasi menggunakan metode ekstraksi ciri tekstur ICRLBP ditunjukkan pada Gambar 3.3. Pada Gambar 3.4 ditunjukkan bagian-bagian detail *preprocessing* dan ekstraksi ciri dari proses klasifikasi.

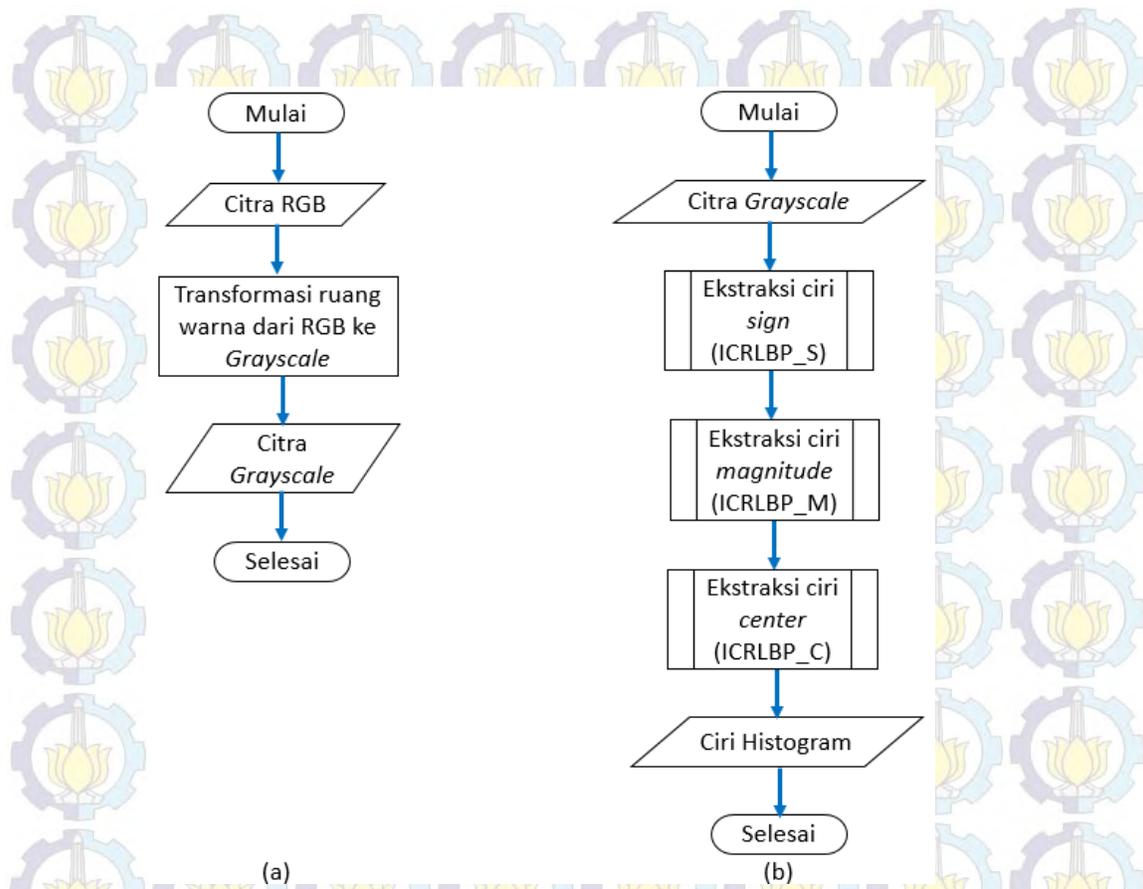
Citra masukan terlebih dahulu diubah ke citra *gray-level*. Dari citra *gray-level* dihitung matrik transformasi WLG dan ALG, dengan menggunakan Persamaan (2.6) dan (2.11). Apabila α yang digunakan pada Persamaan (2.6) sama dengan 1, maka hanya matrik transformasi ALG saja yang dihitung. Dari matrik WLG dan ALG, matrik ICRLBP_S, ICRLBP_M, dan ICRLBP_C dihitung. Pada setiap piksel di citra *gray-level*, perbedaan lokal *sign* dan *magnitude* dihitung untuk memperoleh vektor *sign* dan *magnitude*. Perbedaan lokal *sign* dihitung menggunakan operator ICRLBP_S, seperti yang ditunjukkan

pada Persamaan (2.7). Selanjutnya vektor *sign* ditransformasi ke biner. Vektor *sign* yang berbentuk biner digeser hingga memperoleh kombinasi nilai biner yang terkecil. Kemudian, kombinasi biner terkecil tersebut dikonversi ke bilangan desimal. Dari nilai bilangan desimal masing-masing piksel tersebut dibangun histogram ICRLBP_S.



Gambar 3.3 Proses klasifikasi dengan metode ekstraksi ciri tekstur ICRLBP.

Begitu pula dengan lokal *magnitude*, setiap piksel di citra *gray-level*, perbedaan lokal vektor *magnitude* dihitung dengan menggunakan operator ICRLBP_M, seperti yang ditunjukkan pada Persamaan (2.8). Selanjutnya vektor *magnitude* ditransformasi ke biner. Vektor *magnitude* yang berbentuk biner digeser hingga memperoleh kombinasi nilai biner yang terkecil. Kemudian, kombinasi biner terkecil tersebut dikonversi ke bilangan desimal. Dari nilai bilangan desimal masing-masing piksel tersebut dibangun histogram ICRLBP_M.



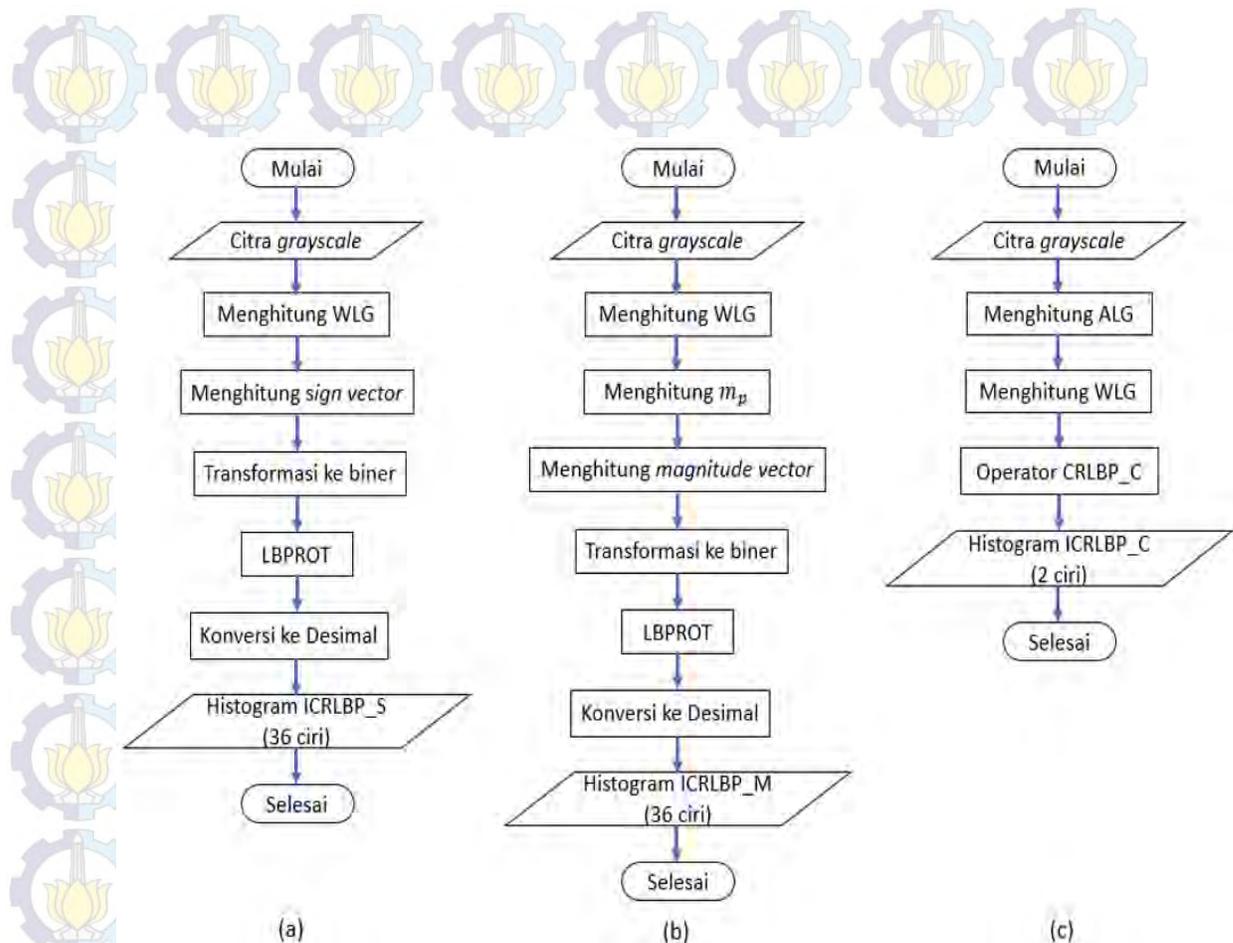
Gambar 3.4 Proses detail dari klasifikasi Batik. (a) *Preprocessing*. (b) Ekstraksi ciri.

Sedangkan representasi dari setiap piksel di citra *gray-level* ketika menjadi piksel pusat lokal dihitung menggunakan operator ICRLBP_C pada Persamaan (2.10). Dari nilai biner pada masing-masing piksel tersebut dibangun histogram ICRLBP_C.

Pada citra *grayscale* dengan operator LBP, P sama dengan 8, maka diperoleh 36 ciri dari histogram CRLBP_S, 36 ciri dari histogram CRLBP_M, dan 2 ciri dari histogram CRLBP_C. Ilustrasi diagram alir untuk metode ekstraksi ciri tekstur ICRLBP_S, ICRLBP_M, dan ICRLBP_C ditunjukkan pada Gambar 3.5.

Kemudian histogram ICRLBP_S, ICRLBP_M, dan ICRLBP_C digabungkan untuk membentuk histogram akhir ICRLBP. Terdapat 2 cara yang digunakan untuk menggabungkan ketiga histogram tersebut seperti yang dijelaskan pada Subbab 2.4, yaitu *concatenation* atau *jointly*.

Selanjutnya, histogram gabungan tersebut akan menjadi data masukkan ke proses klasifikasi PNN.



Gambar 3.5 Ekstraksi ciri dengan metode ICRLBP. (a) ICRLBP_S. (b) ICRLBP_M. (c) ICRLBP_C.

3.4 Perancangan Uji Coba

Kinerja dari ICRLBP diuji dengan beberapa skenario pengujian untuk mengetahui kehandalan metode ICRLBP serta untuk mengetahui dimana kondisi metode ICRLBP yang paling optimal dalam mengklasifikasikan citra Batik. Hal ini disebabkan karena beberapa metode dapat memiliki kondisi optimal yang berbeda pada permasalahan yang berbeda pula.

3.4.1 Pengujian Ciri

Pengujian ini dilakukan untuk mengetahui kombinasi ciri yang teroptimal. Pengujian ini dilakukan dengan beberapa skema, yaitu :

- a. ICRLBP_S
- b. ICRLBP_M

- c. ICRLBP_C.
- d. ICRLBP_S digabung dengan ICRLBP_M.
- e. ICRLBP_S digabung dengan ICRLBP_C.
- f. ICRLBP_M digabung dengan ICRLBP_C.
- g. ICRLBP_S digabung dengan ICRLBP_M dan ICRLBP_C.

3.4.2 Pengujian Metode Penggabungan Histogram

Pengujian ini dilakukan untuk mengetahui metode penggabungan histogram yang teroptimal. Pengujian ini dibagi menjadi 2 skema untuk masing-masing kombinasi ciri, yaitu :

- a. Penggabungan dengan metode *concatenation*.
- b. Penggabungan dengan metode *jointly*.

3.4.3 Pengujian Metode *Padding*

Pengujian ini dilakukan untuk mengetahui pengaruh proses *padding* pada proses klasifikasi. Pada metode ICRLBP, *piksel-piksel* pinggiran akan berkurang karena pengaruh perhitungan WLG dan ekstraksi ciri ICRLBP. Oleh karena itu, pada pengujian kali ini ingin mengetahui apakah dengan berkurangnya *piksel-piksel* pinggiran akan mempengaruhi proses pengenalan pada sistem klasifikasi.

3.4.4 Pengujian Metode *Preprocessing*

Pengujian ini dilakukan untuk mengetahui pengaruh proses *preprocessing* pada proses klasifikasi. Hal ini disebabkan karena sebagian besar citra Batik yang digunakan untuk menguji kehandalan ICRLBP diperoleh dari internet, dimana beberapa citra yang diperoleh dari internet tidak memiliki keadaan yang baik. Contohnya, ada beberapa citra yang *unbalance illumination* dimana keadaan tersebut disebabkan karena tidak meratanya pencahayaan dalam pengambilan citra. Selain itu, ada beberapa citra yang tidak memiliki detail yang jelas.

Oleh karena itu, untuk mengatasi permasalahan tersebut, metode penajaman citra diaplikasikan pada setiap citra. Metode penajaman citra tersebut adalah *adaptive histogram equalization*. *Adaptive histogram equalization* menajamkan citra pada bagian-bagian kecil dari citra atau disebut *tile*. *Adaptive*

histogram equalization menajamkan citra dengan cara meningkatkan kekontrasan citra, karena dengan meningkatnya kekontrasan citra maka detail-detail citra dapat tampak lebih jelas. Kekontrasan citra dilakukan dengan cara menyebar nilai intensitas citra pada histogram, agar nilai intensitas citra tidak mengumpul pada bagian histogram tertentu.

3.4.5 Pengujian Perbandingan CRLBP dengan ICRLBP

Pengujian ini dilakukan untuk mengetahui kinerja LBPROT yang disisipkan pada metode CRLBP sehingga menjadi metode ICRLBP. Hal ini dilakukan dengan harapan dapat mengetahui kehandalan metode ICRLBP dibandingkan dengan metode CRLBP dalam berbagai macam variasi data.

3.4.6 Pengujian dengan Data Batik

Pengujian ini dilakukan untuk mengetahui kinerja metode ICRLBP pada data Batik. Pengujian ini dilakukan dengan beberapa skema, yaitu :

- a. Dalam satu kelas, menggunakan 6 data latih yang diperoleh dari *subsampling* satu citra, dan 23 data uji yang diperoleh dari me-rotasi salah satu citra latih pada sudut 5°, 10°, 15°, 20°, 25°, 30°, 35°, 40°, 45°, 50°, 55°, 60°, 75°, 80°, 85°, 90°, 135°, 180°, 225°, 270°, dan 315°.
- b. Menggunakan 7 macam variasi motif citra Batik dalam satu kelas, dimana masing-masing citra di-*subsampling* menjadi 6 citra. Tiga citra dari masing-masing hasil *subsampling* akan digunakan untuk data latih, dan tiga citra sisanya digunakan untuk data uji.
- c. Menggunakan 7 macam variasi motif citra Batik dalam satu kelas, dimana 4 macam variasi motif untuk data latih dan 3 macam variasi motif untuk data uji. Dari masing-masing citra di-*subsampling* menjadi 6 citra.
- d. Dalam satu kelas, menggunakan 6 data latih yang diperoleh dari *subsampling* satu citra, dan 10 data uji. Lima data uji diperoleh dengan memperkecil salah satu citra latih 90%-50%. Sedangkan, lima data uji

sisanya diperoleh dengan memperbesar salah satu citra latih 110%-150%.

3.4.7 Pengujian dengan Data Brodatz

Pengujian ini dilakukan untuk mengetahui kinerja metode ICRLBP pada data Brodatz. Pengujian ini dilakukan dengan beberapa skema, yaitu :

- a. Dalam satu kelas, menggunakan 6 data latih yang diperoleh dari *subsampling* satu citra, dan 23 data uji yang diperoleh dari me-rotasi salah satu citra latih pada sudut 5°, 10°, 15°, 20°, 25°, 30°, 35°, 40°, 45°, 50°, 55°, 60°, 75°, 80°, 85°, 90°, 135°, 180°, 225°, 270°, dan 315°.
- b. Dalam satu kelas, menggunakan 6 data latih yang diperoleh dari *subsampling* satu citra, dan 10 data uji. Lima data uji diperoleh dengan memperkecil salah satu citra latih 90%-50%. Sedangkan, lima data uji sisanya diperoleh dengan memperbesar salah satu citra latih 110%-150%.

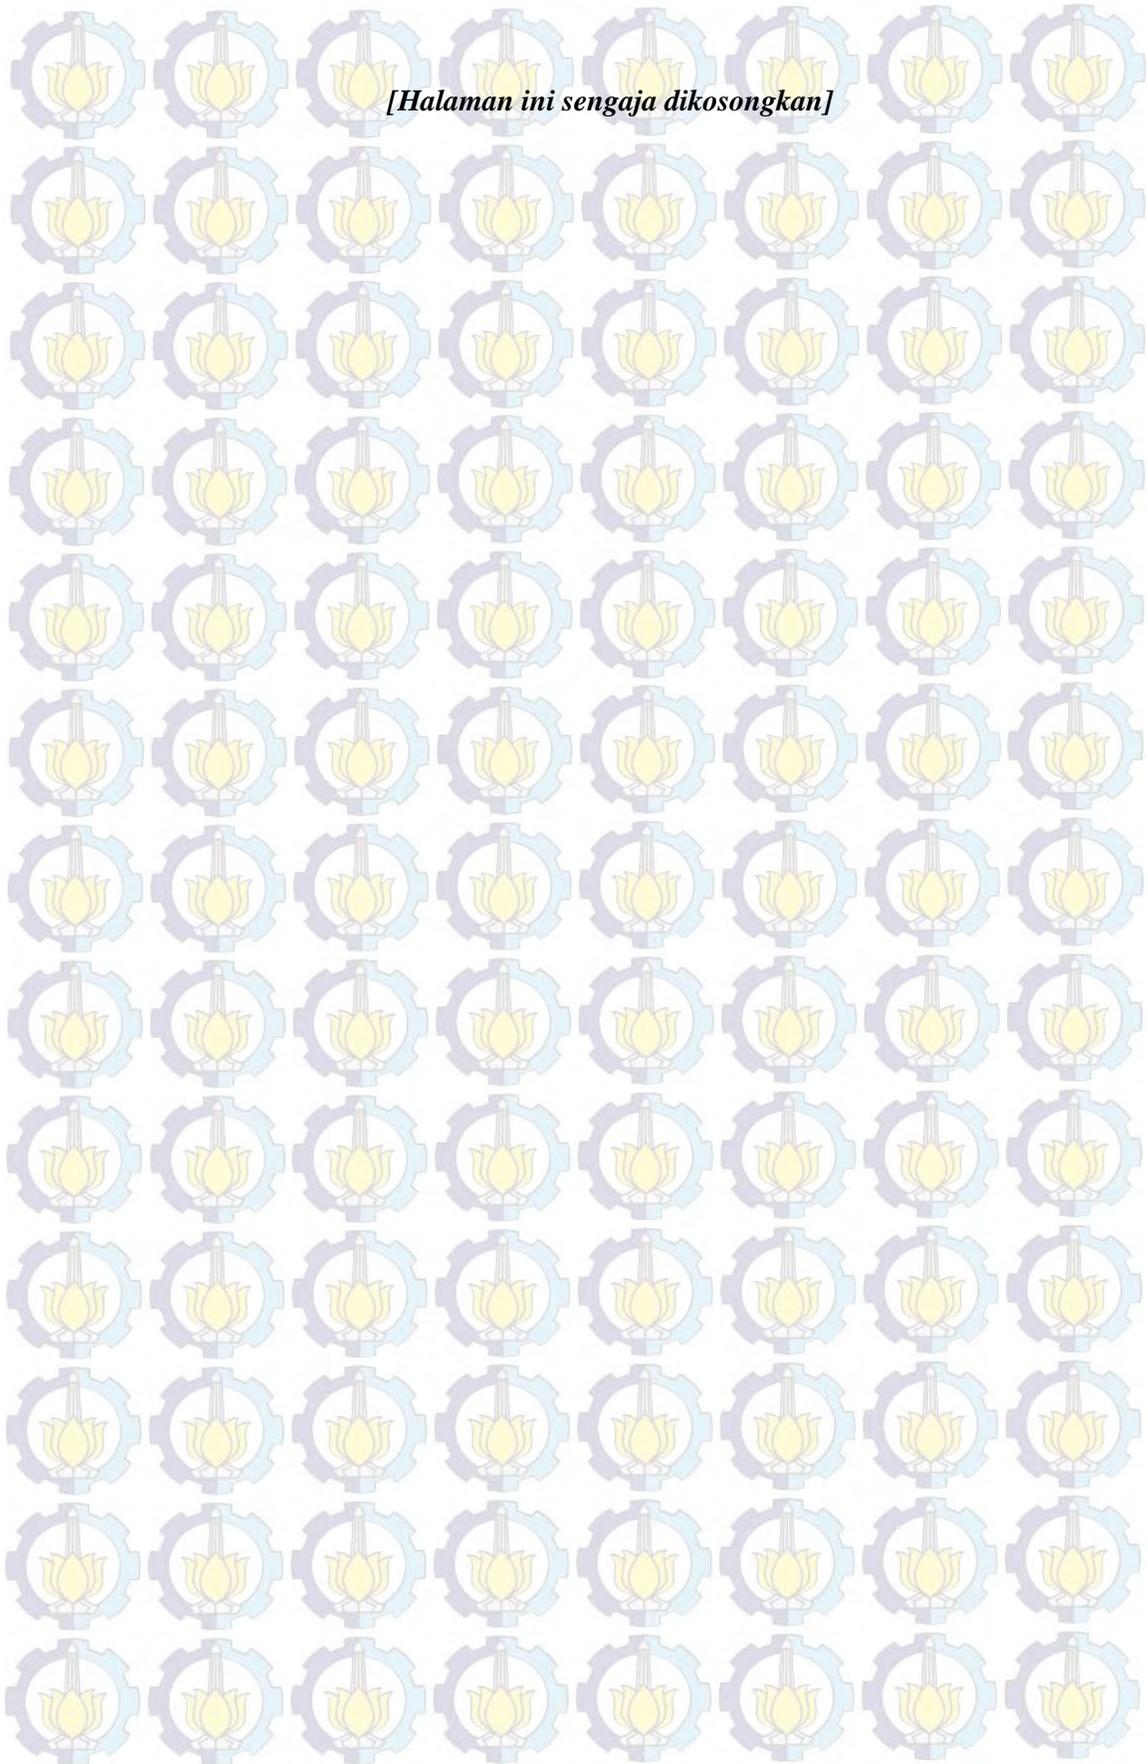
3.5 Evaluasi

Terdapat dua aspek yang akan dinilai dari metode yang diusulkan dalam penelitian ini. Aspek pertama adalah kehandaan sistem dalam mengklasifikasi yang dihitung menggunakan rumus yang ada pada Persamaan (3.1).

$$\text{Akurasi} = \frac{n_b}{N} \times 100\% \quad (3.1)$$

Dimana n_b adalah jumlah data uji yang dikelompokkan dengan tepat, dan N adalah jumlah data uji.

Sedangkan aspek kedua adalah lamanya waktu yang diperlukan sistem untuk mengklasifikasi citra.



BAB 4

PENGUJIAN DAN PEMBAHASAN

Bab 4 berisi penjelasan tentang pengujian dan pembahasan terkait penelitian yang diusulkan. Tahapan pengujian bertujuan untuk menguji metode ICRLBP setelah diimplementasikan. Implementasi dilakukan sesuai dengan yang dijelaskan pada Subbab 3.3 dan diilustrasikan Gambar 3.3. Skenario pengujian tersebut sesuai dengan skenario yang telah direncanakan sebelumnya pada Subbab 3.4 tentang perancangan uji coba. Tahapan terakhir dari bab ini adalah pembahasan tentang hasil dan evaluasi ICRLBP sebagai metode ekstraksi ciri tekstur pada sistem klasifikasi Batik.

4.1 Lingkungan Uji Coba

Untuk melakukan implementasi dan pengujian ICRLBP, pada penelitian ini penulis menggunakan beberapa perangkat yang terdiri dari perangkat keras dan perangkat lunak.

Perangkat keras yang digunakan untuk implementasi dan pengujian adalah satu buah laptop dengan spesifikasi processor Intel Core i5-3317U @1.70 GHz 1.70 GHz, RAM 4 Gb. Sedangkan, Perangkat lunak yang digunakan pada tahapan implementasi dan pengujian adalah Sistem operasi Windows 7 64 bit dan aplikasi Matlab R2012a.

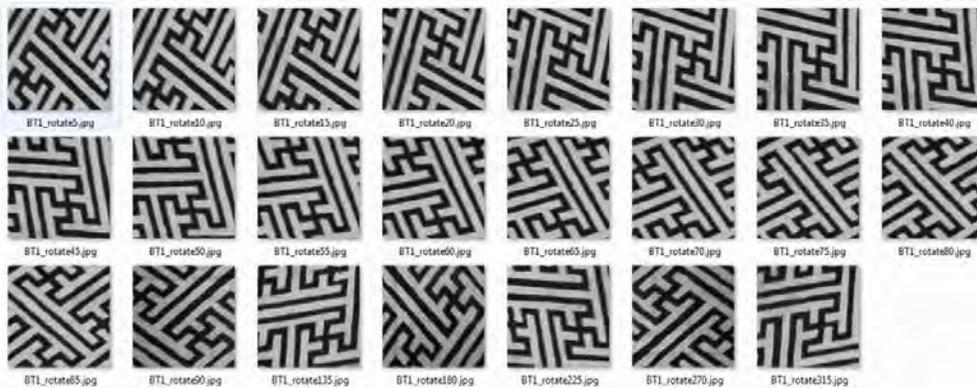
4.2 Dataset

Dataset utama yang digunakan pada penelitian kali ini adalah dataset Batik. Dataset Batik dibagi menjadi dua macam. Pertama dataset untuk pengujian kehandalan metode ICRLBP terhadap *rotation invariant*. Metode ICRLBP diharapkan dapat lebih *invariant* terhadap citra yang dirotasi dalam berbagai macam sudut dibandingkan dengan metode CRLBP. Dataset untuk pengujian metode ICRLBP tersebut hanya memiliki satu variasi motif Batik dalam satu kelas. Citra satu variasi motif Batik tersebut di-*subsampling* 6 bagian sehingga diperoleh 6 citra dari satu variasi motif Batik dimana masing-masing citra

berukuran 128x128. Masing-masing citra tersebut dirotasi pada sudut 5°, 10°, 15°, 20°, 25°, 30°, 35°, 40°, 45°, 50°, 55°, 60°, 75°, 80°, 85°, 90°, 135°, 180°, 225°, 270°, dan 315°. Contoh hasil *subsampling* dan hasil rotasi citra Batik ditunjukkan pada Gambar 4.1 dan 4.2.



Gambar 4.1 Hasil *subsampling* salah satu citra Batik

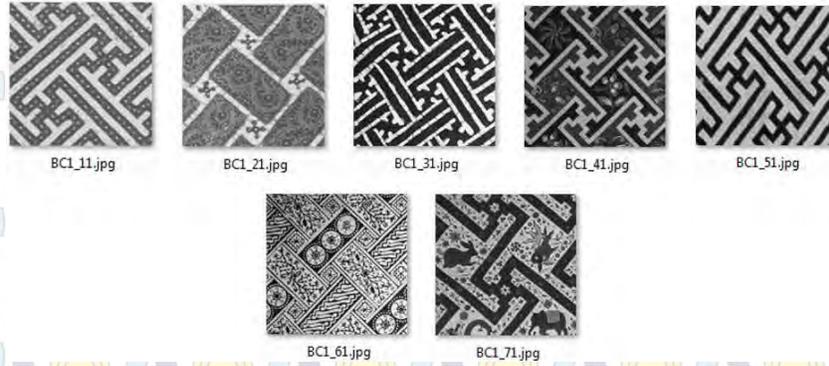


Gambar 4.2 Hasil rotasi salah satu citra Batik

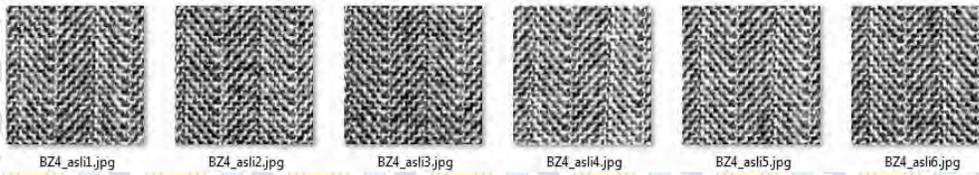
Kedua, dataset Batik untuk pengujian kehandalan metode ICRLBP terhadap kemampuannya dalam mengenali berbagai macam variasi motif citra Batik dalam satu kelas. Dataset untuk pengujian metode ICRLBP tersebut memiliki tujuh variasi motif Batik dalam satu kelas. Masing-masing citra variasi tersebut di-*subsampling* 6 bagian, sehingga diperoleh 6 citra untuk satu variasi motif Batik, dimana masing-masing citra berukuran 128x128. Contoh tujuh variasi motif Batik dalam satu kelas ditunjukkan pada Gambar 4.3.

Dataset kedua yang digunakan pada penelitian kali ini adalah dataset Brodatz. Dataset Brodatz digunakan untuk membuktikan kekonsistenan kehandalan metode ICRLBP yang *invariant* terhadap rotasi. Metode ICRLBP diharapkan lebih *invariant* terhadap rotasi dibandingkan dengan metode CRLBP. Dataset Brodatz mendapat perlakuan yang sama dengan dataset Batik. Satu citra

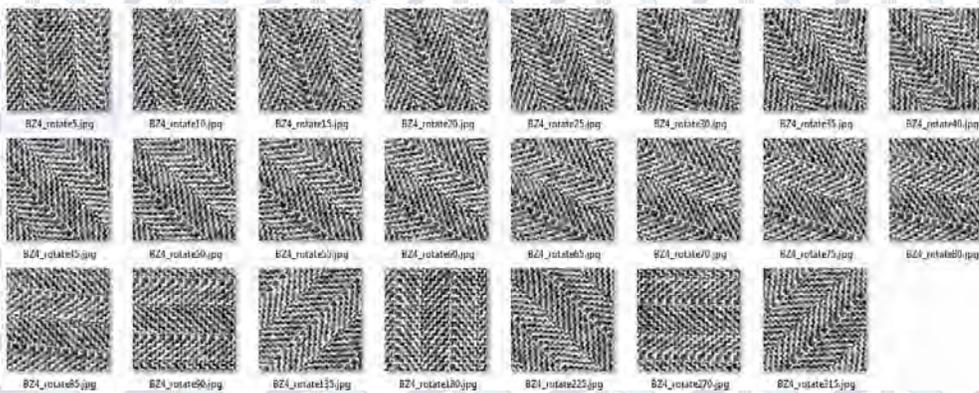
Brodatz di-*subsampling* 6 bagian, sehingga diperoleh 6 citra dari satu citra Brodatz, dimana masing-masing citra berukuran 128x128. Masing-masing citra tersebut dirotasi pada sudut 5°, 10°, 15°, 20°, 25°, 30°, 35°, 40°, 45°, 50°, 55°, 60°, 75°, 80°, 85°, 90°, 135°, 180°, 225°, 270°, dan 315°. Contoh citra hasil *subsampling* dan hasil rotasi citra Brodatz ditunjukkan pada Gambar 4.4 dan 4.5.



Gambar 4.3 Tujuh variasi motif Batik dalam kelas Banjir



Gambar 4.4 Hasil *subsampling* salah satu citra Brodatz



Gambar 4.5 Hasil rotasi salah satu citra Brodatz

4.3 Uji Coba

Kinerja dari ICRLBP diuji dengan beberapa skenario pengujian untuk mengetahui kinerja terbaik metode ICRLBP dalam mengenali ciri tekstur masing-masing citra Batik maupun citra Brodatz.

4.3.1 Pengujian Kombinasi Ciri dan Metode Penggabungan Histogram

Pengujian ini dilakukan untuk mengetahui kombinasi ciri yang paling optimal dalam mengenali ciri tekstur citra Batik maupun citra Brodatz. Seperti ditunjukkan pada Gambar 3.5 ICRLBP memiliki tiga histogram ciri yaitu histogram ICRLBP_S, histogram ICRLBP_M, dan histogram ICRLBP_C. Ketiga histogram tersebut diperoleh dengan perhitungan yang sama pada metode CRLBP, seperti ditunjukkan pada Bab 2.3. Histogram ICRLBP_S dapat diperoleh dengan menggunakan Persamaan 2.7, histogram ICRLBP_M dapat diperoleh dengan menggunakan Persamaan 2.8, sedangkan histogram ICRLBP_C dapat diperoleh dengan menggunakan Persamaan 2.10.

Pengujian selanjutnya adalah metode yang digunakan untuk menggabungkan beberapa histogram ciri tersebut. Menurut Guo pada CLBP (Guo, 2010), ada dua macam cara menggabungkan beberapa histogram ciri tersebut yaitu *concatenation* dan *jointly*, seperti yang telah dijelaskan pada Subbab 2.4.

Oleh karena itu, pengujian kombinasi ciri dan metode penggabungan histogram dilakukan dengan sembilan skema, yaitu :

- a. Pengujian dengan hanya menggunakan ciri ICRLBP_S (S).
- b. Pengujian dengan hanya menggunakan ciri ICRLBP_M (M).
- c. Pengujian dengan hanya menggunakan ciri ICRLBP_C (C).
- d. Pengujian dengan menggabungkan ciri ICRLBP_S dan ICRLBP_M menggunakan metode *concatenation* (SM).
- e. Pengujian dengan menggabungkan ciri ICRLBP_S dan ICRLBP_C menggunakan metode *concatenation* (SC).
- f. Pengujian dengan menggabungkan ciri ICRLBP_M dan ICRLBP_C menggunakan metode *concatenation* (MC).

- g. Pengujian dengan menggabungkan ciri ICRLBP_S, ICRLBP_M, dan ICRLBP_C menggunakan metode *concatenation* (SMC).
- h. Pengujian dengan menggabungkan ciri ICRLBP_S dan ICRLBP_M menggunakan metode *jointly* (S_M).
- i. Pengujian dengan menggabungkan ciri ICRLBP_S dan ICRLBP_C menggunakan metode *jointly* (S_C).
- j. Pengujian dengan menggabungkan ciri ICRLBP_M dan ICRLBP_C menggunakan metode *jointly* (M_C).
- k. Pengujian dengan menggabungkan ciri ICRLBP_S, ICRLBP_M, dan ICRLBP_C menggunakan metode *jointly* (S_M_C).

Sembilan skema pengujian tersebut diujikan pada dataset Batik dan Brodatz. Masing-masing dataset memiliki sembilan kelas, seperti ditunjukkan pada Gambar 3.1 dan Gambar 3.2. Masing-masing dataset dalam satu kelas terdiri atas 6 data latih dan 23 data uji. Enam data latih diperoleh dengan cara *subsampling* satu citra menjadi 6 bagian, seperti yang ditunjukkan pada Gambar 4.1 dan Gambar 4.4. Sedangkan 23 data uji diperoleh dengan merotasi salah satu citra latih pada sudut 5°, 10°, 15°, 20°, 25°, 30°, 35°, 40°, 45°, 50°, 55°, 60°, 75°, 80°, 85°, 90°, 135°, 180°, 225°, 270°, dan 315°, seperti yang ditunjukkan pada Gambar 4.2 dan Gambar 4.5.

Hasil pengujian kombinasi ciri dan metode penggabungan histogram dengan kinerja terbaik diukur menggunakan akurasi ditunjukkan pada Tabel 4.1. Dari Tabel 4.1 menunjukkan bahwa penggabungan ciri ICRLBP_M dan ICRLBP_C menggunakan metode *jointly* merupakan kombinasi ciri yang paling optimal dari metode ICRLBP dalam mengenali ciri citra Batik dan Brodatz, dengan nilai akurasi maksimal yang dapat dicapai adalah 96,14% pada dataset Batik dan 82,13% pada dataset Brodatz.

Hal ini disebabkan karena, ICRLBP_S hanya merepresentasi nilai yang menunjukkan apakah intensitas piksel tetangga lebih kecil atau lebih besar dari rata-rata intensitas piksel pusat. Sehingga, dua citra dari dua kelas yang berbeda yang memiliki beberapa pola struktur yang berbeda, dapat memiliki nilai ICRLBP_S yang sama. Sedangkan ICRLBP_M yang merupakan representasi besarnya nilai perbedaan antara intensitas piksel tetangga dengan intensitas piksel

pusat, dan ICLBP_C yang merupakan nilai representasi dari intensitas piksel pusat terhadap rata-rata nilai intensitas seluruh citra, dapat menggambarkan ciri tekstur lebih detail.

Tabel 4.1 Akurasi hasil pengujian kombinasi ciri dan metode penggabungan histogram

No	Kombinasi ciri	Akurasi ICRLBP (%)	
		Batik	Brodatz
1	S	41.06	19.81
2	M	85.99	71.01
3	C	61.35	23.67
4	SM	68.12	62.80
5	SC	61.35	31.40
6	MC	95.17	61.35
7	SMC	80.68	60.87
8	S_M	66.67	65.22
9	S_C	80.19	41.55
10	M_C	96.14	82.13
11	S_M_C	75.36	54.59

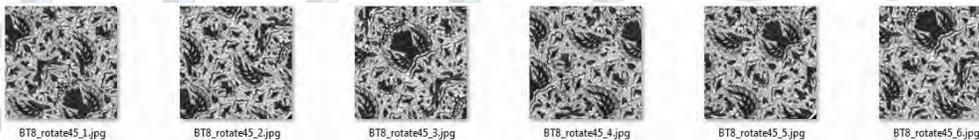
Berdasarkan pada hasil pengujian tersebut, maka pada pengujian selanjutnya, yaitu Subbab 4.3.2 sampai dengan 4.3.6 dilakukan pengujian pada kombinasi ciri ICRLBP_M dan ICRLBP_C dimana kedua histogram tersebut digabung dengan cara *jointly*.

4.3.2 Pengujian Kinerja ICRLBP pada Masing-masing Sudut Rotasi

Untuk mengetahui kinerja pengenalan ciri tekstur ICRLBP pada setiap sudut, ICRLBP diuji dengan 6 data latih dan 6 data uji, pada masing-masing kelas. Enam data latih diperoleh dengan cara *me-subsampling* satu citra menjadi 6 bagian, seperti yang ditunjukkan pada Gambar 4.1 dan 4.4. Sedangkan 6 data uji diperoleh dengan merotasi keenam citra latih pada sudut yang ingin diujikan. Contoh data uji dengan sudut 45° ditunjukkan pada Gambar 4.6.

Hasil pengujian kinerja ICRLBP pada masing-masing sudut rotasi diukur menggunakan akurasi ditunjukkan pada Tabel 4.2. Dari Tabel 4.2 dapat diketahui pada sudut berapa saja nilai akurasi dapat mencapai nilai yang baik dan pada

sudut berapa saja nilai akurasi dapat mencapai nilai yang buruk. Berdasarkan Tabel 4.2 terlihat bahwa rata-rata akurasi yang diperoleh dari pengenalan citra pada masing-masing sudut cukup baik, untuk dataset Batik antara 88,89%-100% sedangkan untuk dataset Brodatz antara 66,67%-100%. Akurasi mencapai nilai yang kurang baik di sekitar sudut 35°-70°. Sedangkan akurasi mencapai nilai yang baik pada kelipatan 90°.



Gambar 4.6 Data uji dengan sudut 45°.

Tabel 4.2 Hasil pengujian kinerja ICRLBP pada masing-masing sudut rotasi

No	Sudut Rotasi	Akurasi ICRLBP (%)	
		Batik	Brodatz
1	5°	100.00	98.15
2	10°	100.00	100.00
3	15°	100.00	87.04
4	20°	100.00	79.63
5	25°	98.15	81.48
6	30°	100.00	72.22
7	35°	94.44	66.67
8	40°	90.74	77.78
9	45°	88.89	74.07
10	50°	88.89	77.78
11	55°	88.89	72.22
12	60°	90.74	72.22
13	65°	88.89	75.93
14	70°	98.15	70.37
15	75°	100.00	83.33
16	80°	100.00	98.15
17	85°	100.00	100.00
18	90°	100.00	98.15
19	135°	88.89	72.22
20	180°	100.00	100.00
21	225°	88.89	77.78
22	270°	100.00	94.44
23	315°	88.89	79.63

4.3.3 Pengujian Metode *Padding*

Pengujian ini dilakukan untuk mengetahui pengaruh penambahan *replicate padding* dan tanpa penambahan *replicate padding* pada hasil proses klasifikasi, yaitu apakah dengan berkurangnya *piksel-piksel* pinggiran akan mempengaruhi proses pengenalan pada sistem klasifikasi. Pada proses ICRLBP, setelah melewati proses perhitungan WLK, ukuran citra akan berkurang sebesar 1 baris piksel pada baris teratas, 1 baris piksel pada baris terbawah, 1 kolom piksel pada kolom terkanan, dan 1 kolom piksel pada kolom ter kiri. Oleh karena itu, untuk mengembalikan citra pada ukurannya semula maka dilakukan proses *replicate padding*.

Pengujian tersebut diujikan pada dataset Batik dan Brodatz, dengan komposisi data latih dan data uji sama seperti pada pengujian kombinasi ciri dan metode penggabungan histogram, pada Subbab 4.2.1.

Hasil pengujian kinerja ICRLBP dengan penambahan *replicate padding*, diukur menggunakan akurasi ditunjukkan pada Tabel 4.3.

Tabel 4.3 Akurasi hasil pengujian kinerja ICRLBP dengan penambahan *replicate padding*.

No	Dataset	Akurasi ICRLBP tanpa <i>padding</i> (%)	Akurasi ICRLBP dengan <i>padding</i> (%)
1	Batik	96.14	95.65
2	Brodatz	82.13	82.13

Dari Tabel 4.3 menunjukkan bahwa penambahan *replicate padding* pada hasil WLK, tidak begitu *significant* pengaruhnya pada proses klasifikasi. Nilai akurasi yang diperoleh tidak terlalu berbeda antara metode ICRLBP yang ditambah *replicate padding* dengan metode ICRLBP tanpa ditambah *replicate padding*. Hal ini disebabkan karena hanya sedikit dari keseluruhan *piksel* pada citra yang tidak dilibatkan dalam proses ekstraksi ciri, yaitu tidak lebih dari 7% dari keseluruhan jumlah *piksel* citra. Oleh karena itu, proses *replicate padding* pada metode ICRLBP tidak begitu diperlukan.

4.3.4 Pengujian Metode *Preprocessing*

Pengujian ini dilakukan untuk mengetahui pengaruh penambahan *preprocessing* pada proses klasifikasi. Metode *preprocessing* yang digunakan adalah *Adaptive histogram equalization*. Pengujian metode *preprocessing* tersebut diaplikasikan khususnya pada citra Batik. Hal ini disebabkan karena sebagian besar citra Batik yang digunakan untuk menguji kehandalan ICRLBP diperoleh dari internet, dimana beberapa citra yang diperoleh dari internet tidak memiliki keadaan yang baik. Contohnya, ada beberapa citra yang *unbalance illumination* dimana keadaan tersebut disebabkan karena tidak meratanya pencahayaan dalam pengambilan citra. Selain itu, ada beberapa citra yang tidak memiliki detail yang jelas.

Pengujian metode *preprocessing* diujikan pada dataset citra Batik yang memiliki 9 kelas dengan 2 variasi, yaitu :

- a. Menggunakan 7 macam variasi motif citra Batik dalam satu kelas seperti ditunjukkan pada Gambar 4.3. Masing-masing citra di-*subsampling* menjadi 6 citra, seperti ditunjukkan pada Gambar 4.1. Tiga citra dari masing-masing hasil *subsampling* akan digunakan untuk data latih, dan tiga citra sisanya digunakan untuk data uji. (Variasi 1).
- b. Menggunakan 7 macam variasi motif citra Batik dalam satu kelas, seperti ditunjukkan pada Gambar 4.3. Empat macam variasi motif digunakan untuk data latih dan 3 macam variasi motif sisanya digunakan untuk data uji. Dari masing-masing citra di-*subsampling* menjadi 6 citra, seperti ditunjukkan pada Gambar 4.1. (Variasi 2).

Hasil pengujian kinerja ICRLBP dengan penambahan *preprocessing* diukur menggunakan akurasi ditunjukkan pada Tabel 4.4. Dari Tabel 4.4, pada variasi 1, penambahan metode *preprocessing* pada metode ICRLBP tidak begitu terlihat pengaruhnya. Hal ini disebabkan metode ICRLBP tanpa *preprocessing* dan metode ICRLBP dengan *preprocessing*, dapat mencapai nilai akurasi yang paling maksimal yaitu 100%. Akurasi 100% dapat dicapai karena variasi citra pada data uji telah dilatih pada proses pelatihan. Data latih dan data uji memiliki citra yang hampir sama karena merupakan hasil *subsampling* pada satu citra yang sama.

Sedangkan pada variasi 2, pengaruh penambahan *preprocessing* pada metode ICRLBP sedikit berpengaruh, yaitu dengan meningkatnya nilai akurasi sekitar 6,17% dari akurasi 41,36% menjadi 47,53%. Peningkatan nilai akurasi dapat disebabkan karena ada beberapa citra yang memerlukan proses penajaman atau proses meratakan pencahayaan pada citra. Hal ini dikarenakan sebagian besar citra Batik yang diperoleh dari internet tidak memiliki keadaan yang baik.

Tabel 4.4 Akurasi hasil pengujian kinerja ICRLBP dengan penambahan *preprocessing*.

No	Data Batik	Akurasi CRLBP (%)	Akurasi ICRLBP (%)	
			tanpa <i>preprocessing</i>	dengan <i>preprocessing</i>
1	Variasi 1	89.42	100.00	100.00
2	Variasi 2	34.57	41.36	47.53

Selain ingin mengetahui pengaruh penambahan *preprocessing* pada proses klasifikasi, pada subbab kali ini bertujuan untuk mengetahui kehandalan ICRLBP dalam mengekstraksi ciri pada dataset Batik yang memiliki berbagai macam variasi motif citra Batik dalam satu kelas, seperti yang ditunjukkan pada Gambar 4.3. Citra Batik memiliki tantangan tersendiri dalam proses pengklasifikasian, dimana pada keadaan sesungguhnya, citra Batik dalam satu kelas atau satu jenis motif utama dapat memiliki berbagai macam variasi perpaduan antara motif utama dengan motif pengisi atau *isen-isen*. Seperti ditunjukkan pada Gambar 4.3, pada kelas Banji terdapat 7 variasi jenis perpaduan antara motif utama dengan motif pengisi atau *isen-isen*. Pada Gambar 4.3 dapat disimpulkan bahwa hanya motif utama saja yang sama dalam satu kelas. Sehingga dibutuhkan metode yang handal dalam mengenali motif utama dari citra Batik yang variasi perpaduannya sangat banyak seiring perkembangan kreasi seni Batik.

Pada Tabel 4.4 menunjukkan bahwa pada variasi dataset Batik, baik variasi 1 maupun variasi 2, metode ICRLBP lebih unggul dari metode CRLBP. Pada dataset Batik diperoleh peningkatan akurasi sebesar 10,58%, yaitu dari 89,42% menjadi 100%. Sedangkan pada dataset Brodatz diperoleh peningkatan akurasi sebesar 12,96% dari 34,57% menjadi 47,53%. Hal ini menunjukkan bahwa metode ICRLBP lebih handal dalam mengekstraksi ciri penting dari suatu

citra, sehingga mampu mengenali ciri utama dari suatu kelas walau dalam satu kelas memiliki berbagai macam variasi motif.

Namun, akurasi yang dicapai oleh metode ICRLBP pada kasus variasi motif tidak memuaskan, dimana akurasi maksimal yang dapat dicapai hanya 47,53%. Sehingga dibutuhkan metode tambahan yang dapat membantu dalam mengenali motif utama dari suatu citra Batik, atau metode yang dapat menghilangkan *isen-isen* pada citra Batik.

4.3.5 Pengujian ICRLBP dengan Ukuran Skala Citra yang Berbeda

Pengujian ini untuk mengetahui kehandalan kinerja ICRLBP dibandingkan dengan CRLBP pada citra uji dengan ukuran skala yang berbeda. Hal ini dilakukan karena pada keadaan sesungguhnya citra yang beredar di internet terdiri atas berbagai macam ukuran.

ICRLBP diuji dengan dataset Batik dan Brodatz, dimana masing-masing dataset memiliki 9 kelas. Masing-masing kelas memiliki 6 data latih dan 10 data uji. Enam data latih diperoleh dengan cara *me-subsampling* citra menjadi 6 bagian, seperti yang ditunjukkan pada Gambar 4.1 dan Gambar 4.4. Sedangkan 10 data uji diperoleh dengan cara memperkecil salah satu citra latih 90%-50%. Sedangkan, lima data uji sisanya diperoleh dengan memperbesar salah satu citra latih 110%-150%. Contoh data uji salah satu kelas Batik ditunjukkan pada Gambar 4.7.

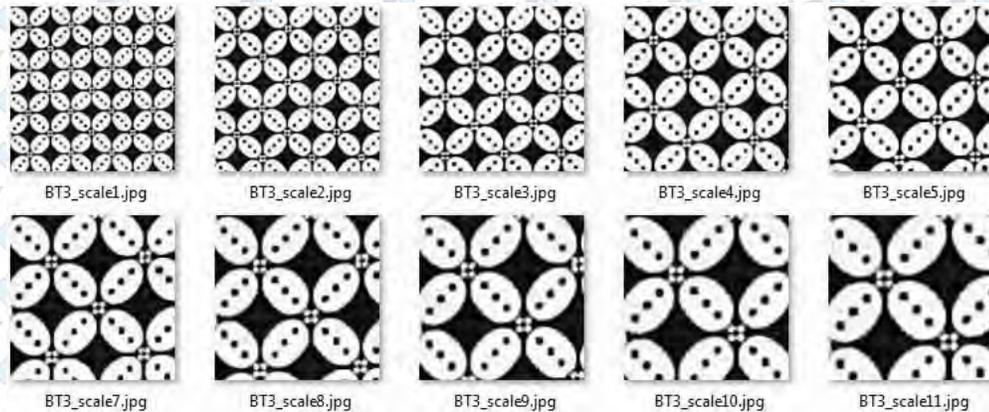
Hasil pengujian kinerja ICRLBP pada ukuran citra yang berbeda diukur menggunakan akurasi ditunjukkan pada Tabel 4.5.

Tabel 4.5 Akurasi hasil pengujian kinerja ICRLBP pada ukuran skala citra yang berbeda

No	Dataset	Akurasi CRLBP (%)	Akurasi ICRLBP (%)
1	Batik	81.11	84.44
2	Brodatz	77.78	81.11

Dari Tabel 4.5 menunjukkan bahwa ICRLBP sedikit lebih handal dibandingkan CRLBP dalam mengklasifikasi beberapa citra yang memiliki ukuran skala yang berbeda. Pada dataset Batik maupun dataset Brodatz terjadi

peningkatan akurasi sebesar 3,33%. Pada dataset Batik peningkatan akurasi diperoleh dari 81,11% menjadi 84,44%. Sedangkan pada dataset Brodatz peningkatan diperoleh dari 77,78% menjadi 81,11%.



Gambar 4.7 Data uji *scaling* pada kelas Ceplok

Namun, ICRLBP tidak dirancang untuk mengekstraksi ciri pada data citra yang memiliki ukuran skala berbeda. Selain itu, diharapkan akurasi yang dicapai oleh metode ICRLBP pada kasus data citra dengan ukuran skala yang berbeda dapat ditingkatkan lagi. Sehingga dibutuhkan metode tambahan yang dapat membantu dalam mengenali motif utama pada dataset citra yang memiliki ukuran skala yang berbeda-beda.

4.3.6 Pengujian Perbandingan CRLBP dengan ICRLBP

Pengujian ini dilakukan untuk mengetahui kehandalan kinerja ICRLBP dalam mengklasifikasikan citra yang memiliki variasi rotasi. ICRLBP diusulkan untuk memperbaiki CRLBP dengan menyisipkan metode LBPROT ke metode CRLBP, sehingga dihasilkan metode ICRLBP yang *invariant* terhadap rotasi. Kehandalan dari kinerja metode ICRLBP diperoleh dengan cara membandingkan metode ICRLBP dengan metode CRLBP.

Pengujian tersebut diujikan pada dataset Batik dan Brodatz, dengan komposisi jumlah kelas, jumlah data latih, dan jumlah data uji sama seperti pada pengujian kombinasi ciri dan metode penggabungan histogram, pada Subbab 4.2.1.

Hasil pengujian perbandingan CRLBP dengan ICRLBP diukur menggunakan akurasi ditunjukkan pada Tabel 4.6. Dari Tabel 4.6 menunjukkan bahwa metode ICRLBP lebih unggul dari metode CRLBP. Pada dataset Batik diperoleh peningkatan akurasi sebesar 17,39%, yaitu dari 78,74% menjadi 96,14%. Sedangkan pada dataset Brodatz diperoleh peningkatan akurasi sebesar 37,20% dari 44,93% menjadi 82,13%.

Tabel 4. 6 Akurasi hasil pengujian perbandingan CRLBP dengan ICRLBP

No	Dataset	Akurasi CRLBP (%)	Akurasi ICRLBP (%)
1	Batik	78.74	96.14
2	Brodatz	44.93	82.13

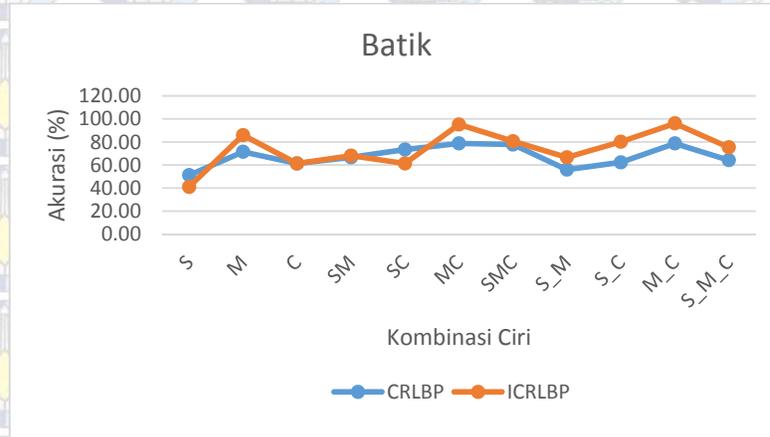
Tujuan diusulkan metode ICRLBP adalah agar dapat meningkatkan kehandalan kinerja metode CRLBP dalam pengklasifikasian ciri tekstur citra terutama pada citra yang dirotasi pada berbagai macam jenis sudut, sehingga dapat meningkatkan kinerja sistem klasifikasi. Meningkatnya kinerja sistem klasifikasi ditandai dengan meningkatnya nilai akurasi hasil pengklasifikasian. Sehingga dapat disimpulkan bahwa metode ICRLBP dapat meningkatkan kehandalan metode CRLBP.

4.4 Pembahasan

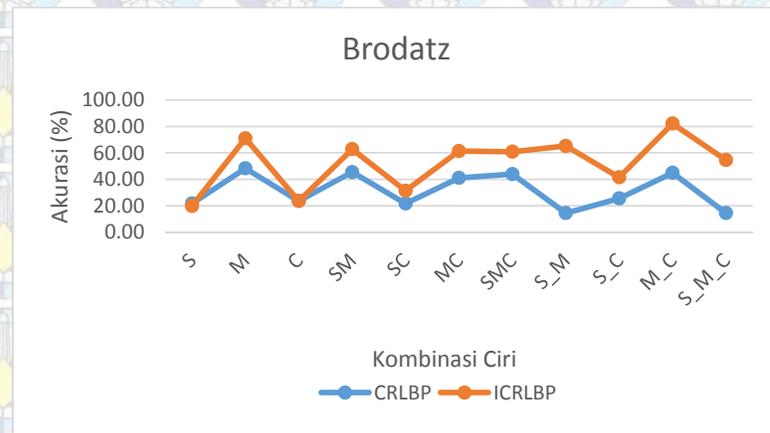
Perbedaan utama antara metode ICRLBP dengan CRLBP adalah adanya penyisipan metode ekstraksi ciri LBPROT pada CRLBP, dimana metode LBPROT memiliki kehandalan *invariant* terhadap rotasi. Sehingga, metode ICRLBP yang dihasilkan diharapkan dapat memperbaiki metode CRLBP menjadi metode ekstraksi ciri yang *invariant* terhadap rotasi.

Aspek pertama untuk menunjukkan kehandalan kinerja metode ICRLBP dibandingkan dengan CRLBP adalah nilai akurasi. Dari keseluruhan hasil pengujian perbandingan kinerja antara CRLBP dan ICRLBP menunjukkan bahwa akurasi ICRLBP secara konsisten lebih tinggi dibandingkan dengan akurasi CRLBP. Hal ini menunjukkan bahwa metode ICRLBP terbukti dapat memperbaiki kinerja metode CRLBP, terutama pada kasus pengklasifikasian citra yang memiliki variasi rotasi pada satu kelas. Seperti yang ditunjukkan pada Tabel

4.6, perbaikan metode ICRLBP ditunjukkan dengan adanya peningkatan akurasi sebesar 17,39%, pada dataset Batik. Sedangkan pada dataset Brodatz diperoleh peningkatan akurasi sebesar 37,20%. Selain itu, pada Gambar 4.8 dan 4.9 menunjukkan bahwa pada sebagian besar kombinasi ciri, ICRLBP dapat mengungguli CRLBP.



Gambar 4.8 Perbandingan metode ICRLBP dengan CRLBP pada dataset Batik



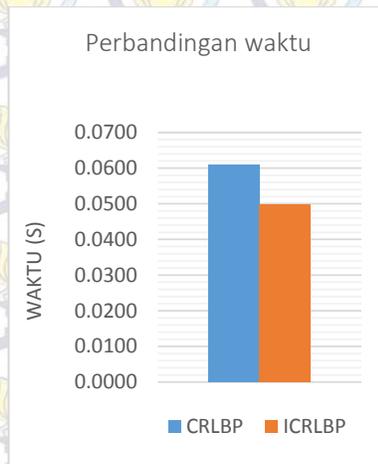
Gambar 4.9 Perbandingan metode ICRLBP dengan CRLBP pada dataset Brodatz

Aspek kedua untuk menunjukkan kehandalan kinerja metode ICRLBP dibandingkan dengan CRLBP adalah lamanya waktu yang diperlukan sistem untuk mengklasifikasi citra. Dari sisi kecepatan proses ekstraksi ciri, waktu yang dibutuhkan metode ICRLBP untuk mengekstraksi ciri hampir sama dengan metode CRLBP. Perbandingan kecepatan proses ekstraksi ciri antara ICRLBP

dengan CRLBP pada satu citra ditunjukkan pada Tabel 4.7 dan Gambar 4.10. Dari Tabel 4.7 dan Gambar 4.10 menunjukkan bahwa tidak terjadi perbedaan waktu yang *significant* antara proses ekstraksi ciri CRLBP dengan ICRLBP. Perbedaan waktu antara proses ekstraksi ciri CRLBP dengan ICRLBP hanya sekitar 0,0112 detik.

Tabel 4.7 Perbandingan kecepatan proses ekstraksi ciri CRLBP dengan ICRLBP

No	Metode	Waktu (s)
1	CRLBP	0.0611
2	ICRLBP	0.0498



Gambar 4.10 Perbandingan kecepatan proses ekstraksi ciri CRLBP dengan ICRLBP

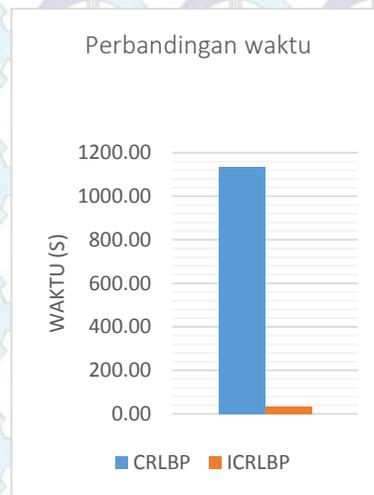
Dari sisi kecepatan proses klasifikasi, waktu yang dibutuhkan metode ICRLBP untuk mengklasifikasi beberapa citra lebih cepat dibandingkan dengan metode CRLBP. Perbandingan kecepatan proses klasifikasi antara ICRLBP dengan CRLBP pada satu citra ditunjukkan pada Tabel 4.8 dan Gambar 4.11. Perbedaan waktu antara proses klasifikasi CRLBP dengan ICRLBP adalah 1101,83 detik atau sekitar 18 menit, dimana metode ICRLBP lebih cepat 300 kali lebih cepat dibandingkan dari metode CRLBP.

Hal ini dapat terjadi karena, metode ICRLBP memiliki jumlah ciri yang lebih sedikit dibandingkan metode CRLBP. ICRLBP memiliki jumlah ciri

masing-masing 36 untuk histogram ICRLBP_S, 36 untuk histogram ICRLBP_M, dan 2 untuk histogram ICRLBP_C. Sedangkan CRLBP memiliki jumlah ciri masing-masing 256 untuk histogram CRLBP_S, 256 untuk histogram ICRLBP_M, dan 2 untuk histogram ICRLBP_C.

Tabel 4.8 Perbandingan kecepatan proses klasifikasi CRLBP dengan ICRLBP

No	Metode	Waktu (s)
1	CRLBP	1135.46
2	ICRLBP	33.64



Gambar 4.11 Perbandingan kecepatan proses klasifikasi CRLBP dengan ICRLBP

Namun, ICRLBP tidak terlepas dari kesalahan dalam mengklasifikasikan citra, terutama pada dataset Brodatz. Pada sebagian besar hasil pengujian, nilai akurasi maksimal yang dicapai dengan menggunakan dataset Brodatz selalu lebih rendah dibandingkan dengan nilai akurasi maksimal yang dicapai dengan menggunakan dataset Batik. Hal ini dapat terjadi, karena pada dataset Brodatz tingkat kemiripan satu citra dengan citra lain di kelas yang berbeda lebih tinggi dibandingkan pada dataset Batik. Hal ini dapat dibandingkan dengan cara memperhatikan Gambar 3.1 dan 3.2.

Tabel 4.9 Kesalahan klasifikasi data uji pada dataset Batik

No	Sudut Rotasi	Jumlah data uji yang tidak diklasifikasi dengan benar. (Kelas target uji → kelas hasil uji).				
		6 → 4	1 → 3	6 → 7	6 → 5	6 → 2
1	5°					
2	10°	1				
3	15°					
4	20°					
5	25°		1			
6	30°	1				
7	35°	3				
8	40°	5				
9	45°	5		1		
10	50°	5		2		
11	55°	5				1
12	60°	3	2			
13	65°	2	5			
14	70°		1			
15	75°	1				
16	80°	1				
17	85°		1			
18	90°		1			
19	135°	5				1
20	180°					
21	225°	5			1	
22	270°					
23	315°	5			1	
	Jumlah	47	11	3	2	2

Dari sekumpulan data uji yang diujikan pada berbagai macam skenario pengujian, dataset Batik hanya melakukan kesalahan klasifikasi sebanyak 65 citra uji, sedangkan dataset Brodatz melakukan kesalahan klasifikasi sebanyak 247 citra uji, dari 1449 keseluruhan data uji yang berasal dari pengujian pada Subbab 4.3.1 dan 4.3.2. Pada Subbab 4.3.1, dataset Batik hanya melakukan kesalahan klasifikasi sebanyak 8 citra uji, dan dataset Brodatz melakukan kesalahan klasifikasi sebanyak 37 citra uji, dari 207 keseluruhan data uji. Sedangkan, pada Subbab 4.3.2, dataset Batik hanya melakukan kesalahan klasifikasi sebanyak 57 citra uji, dan dataset Brodatz melakukan kesalahan klasifikasi sebanyak 210 citra

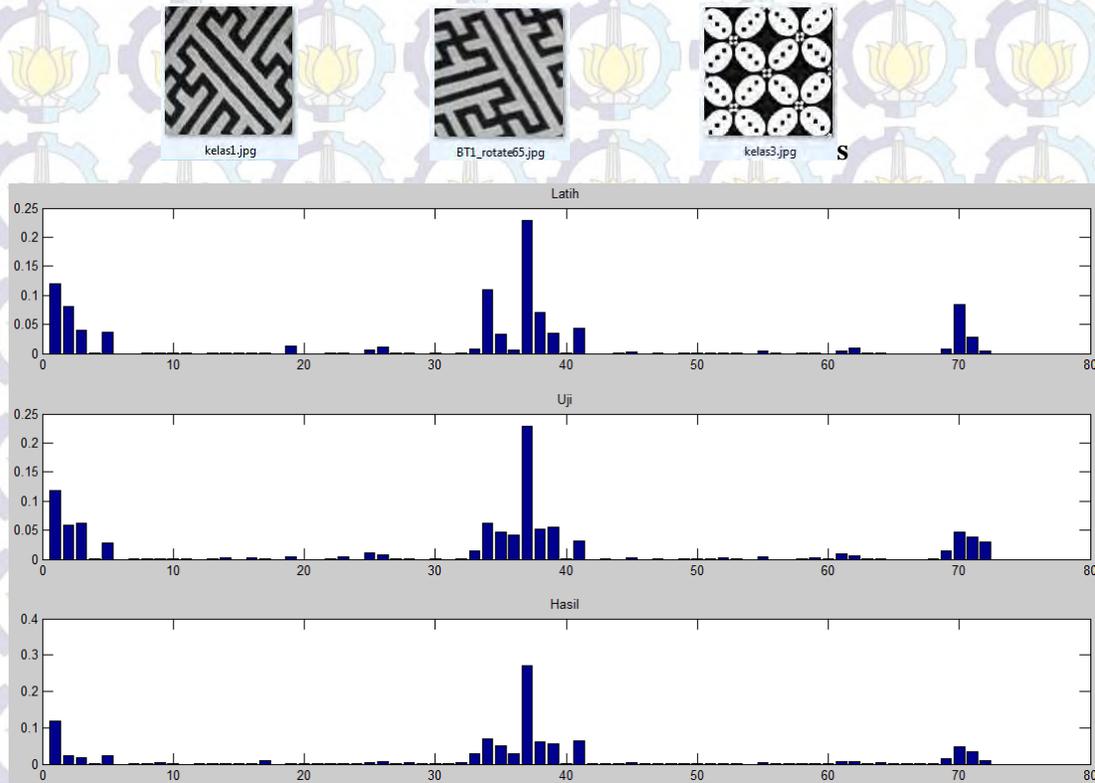
uji, dari 1242 keseluruhan data uji. Berbagai macam kesalahan klasifikasi data uji ditunjukkan pada Tabel 4.9 untuk citra Batik, dan Tabel 4.10 untuk citra Brodatz.

Tabel 4.10 Kesalahan klasifikasi data uji pada dataset Brodatz

no	Sudut Rotasi	Jumlah data uji yang tidak diklasifikasi dengan benar. (Kelas target uji → kelas hasil uji).													
		7 → 3	3 → 6	8 → 9	7 → 8	3 → 7	6 → 1	6 → 5	5 → 1	7 → 2	9 → 2	7 → 9	1 → 5	1 → 6	4 → 1
1	5°										1				
2	10°	1	1												
3	15°			3	6										
4	20°	5		4						1	1				
5	25°	5		5						1		1			
6	30°	6	2	6	1		2	1					1		
7	35°	7	5	6			2								
8	40°	6	5				1								
9	45°	6	5	1	1	1	1	1							
10	50°	5	2	1	2	3		1	1						
11	55°	6	2	3	1	3		1							1
12	60°	6	3	3		3		1	1			1			
13	65°	6	4	2		1					1	1			
14	70°	6	6	4											
15	75°		1	2	5	1				2					
16	80°	1		1		1									
17	85°	1				1									
18	90°	1	1						1						
19	135°	5	6		2	1	1		2						
20	180°		1							1					
21	225°	1	4		5									2	
22	270°								1		1		1		
23	315°	3	1		3			2	1		1				
	Jumlah	77	49	41	26	15	7	7	7	5	5	3	2	2	1

Pada Tabel 4.10, “7 → 3” berarti data uji yang memiliki target uji, atau kelas seharusnya, kelas 7, diklasifikasikan dengan salah oleh sistem klasifikasi pada kelas hasil uji yaitu kelas 3. Dari Tabel 4.9 dan 4.10 dapat terlihat dimana kesalahan sering terjadi. Pada dataset Batik, kesalahan klasifikasi yang sering terjadi adalah citra dari kelas 6 (Udan liris) yang diklasifikasikan ke kelas 4

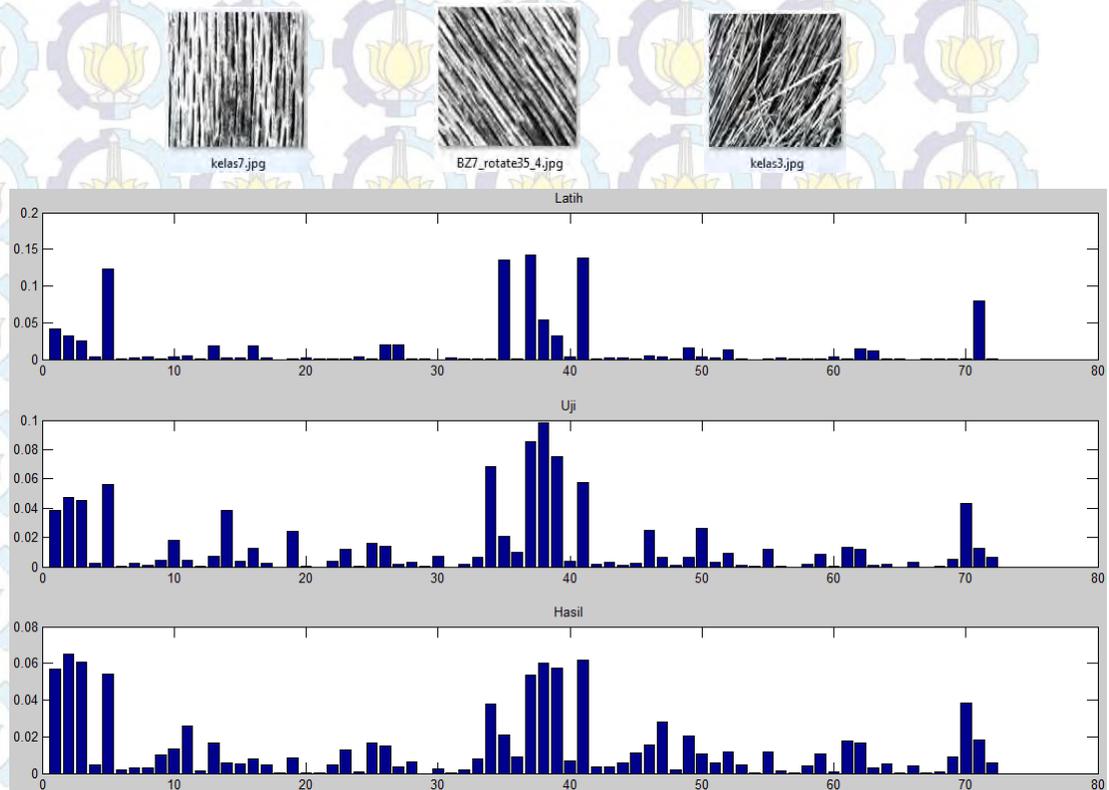
(Nitik) sebanyak 47 citra uji, dan citra dari kelas 1 (Banji) yang diklasifikasikan ke kelas 3 (Kawung) sebanyak 11 citra uji.



Gambar 4.12 Histogram citra Batik. (a) Data latih kelas 1 (Banji). (b) Data uji kelas 1 (Banji) pada sudut 65° yang salah dikenali menjadi (c) kelas 3 (Kawung).

Sedangkan pada dataset Brodatz, kesalahan klasifikasi yang sering terjadi adalah citra dari kelas 7 (Wood grain-D68) yang diklasifikasikan ke kelas 3 (Straw-D15) sebanyak 77 citra uji, citra dari kelas 3 (Straw-D15) yang diklasifikasikan ke kelas 6 (Pressed calf leather-D24) sebanyak 49 citra uji, citra dari kelas 8 (Brick wall-D94) yang diklasifikasikan ke kelas 9 (Plastic bubbles-D112) sebanyak 41 citra uji, citra dari kelas 7 (Wood grain-D68) yang diklasifikasikan ke kelas 8 (Brick wall-D94) sebanyak 26 citra uji, dan citra dari kelas 3 (Straw-D15) yang diklasifikasikan ke kelas 7 (Wood grain-D68) sebanyak 15 citra uji.

Kesalahan proses klasifikasi dapat terjadi karena satu citra memiliki histogram ICRLBP yang mirip dengan citra lain dalam kelas yang berbeda pada sudut rotasi tertentu. Oleh karena itu, nilai-nilai ciri histogram antar kelas terlalu dekat. Kedekatan histogram tersebut ditunjukkan pada Gambar 4.12 untuk dataset Batik dan Gambar 4.13 pada dataset Brodatz. Gambar 4.13 menunjukkan bahwa histogram data uji yang seharusnya mirip dengan histogram data latihnya, ternyata pada sudut rotasi tertentu, histogram data uji lebih mirip pada data latih di kelas yang berbeda.



Gambar 4.13 Histogram citra Brodatz. (a) Data latih kelas 7 (Wood grain-D68), (b) Data uji kelas 7 (Wood grain-D68) pada sudut 35° yang salah dikenali menjadi (c) kelas 3 (Strain-D15).

Kesalahan proses pengklasifikasian tersebut dapat dikurangi dengan memvariasi data latih pada proses pelatihan. Seperti ditunjukkan pada Tabel 4.11 dan 4.12, yang merupakan hasil dari *cross validation*. Pada proses *cross validation*, dataset yang ada diacak untuk beberapa dijadikan data latih dan

beberapa dijadikan data uji. Pada proses *cross validation* kali ini, data diacak sebanyak 5 kali ($k=5$), untuk menukar posisi citra sebagai data latih dan data uji. Diharapkan semua data pernah menjadi data latih dan data uji. Kemudian hasil dari proses *cross validation* tersebut dirata-rata untuk memperoleh nilai maksimum yang dapat dicapai proses klasifikasi menggunakan metode ICRLBP.

Seperti ditunjukkan pada Tabel 4.11 dan Tabel 4.12, akurasi maksimum rata-rata yang dapat dicapai untuk dataset Batik dari hasil *cross validation* adalah 99,91%. Sedangkan pada dataset Brodatz akurasi maksimum rata-rata yang dapat dicapai dari hasil *cross validation* adalah 93.22%, seperti ditunjukkan pada Tabel 4.10. Hal ini membuktikan bahwa dengan adanya variasi sudut rotasi pada data latih, dapat meningkatkan proses klasifikasi dalam mengklasifikasi data uji pada kelas yang seharusnya.

Tabel 4.11 Hasil *cross validation* ICRLBP pada dataset Batik

no	Kombinasi ciri	<i>Cross validation</i>					Rata-Rata
1	S	59.90	68.60	62.32	63.43	61.84	63.22
2	M	81.16	82.61	82.13	81.02	81.16	81.61
3	C	62.32	65.70	64.25	69.91	65.70	65.58
4	SM	78.74	79.23	80.19	81.48	79.71	79.87
5	SC	87.44	84.54	80.19	81.94	84.54	83.73
6	MC	87.44	87.44	83.57	86.57	90.82	87.17
7	SMC	91.30	89.86	95.17	87.96	91.79	91.22
8	S_M	71.50	75.36	70.05	75.46	78.26	74.13
9	S_C	93.24	90.82	93.24	91.20	94.69	92.64
10	M_C	100.00	100.00	100.00	99.54	100.00	99.91
11	S_M_C	84.54	80.19	71.98	78.70	89.37	80.96

Tabel 4.12 Hasil *cross validation* ICRLBP pada dataset Brodatz

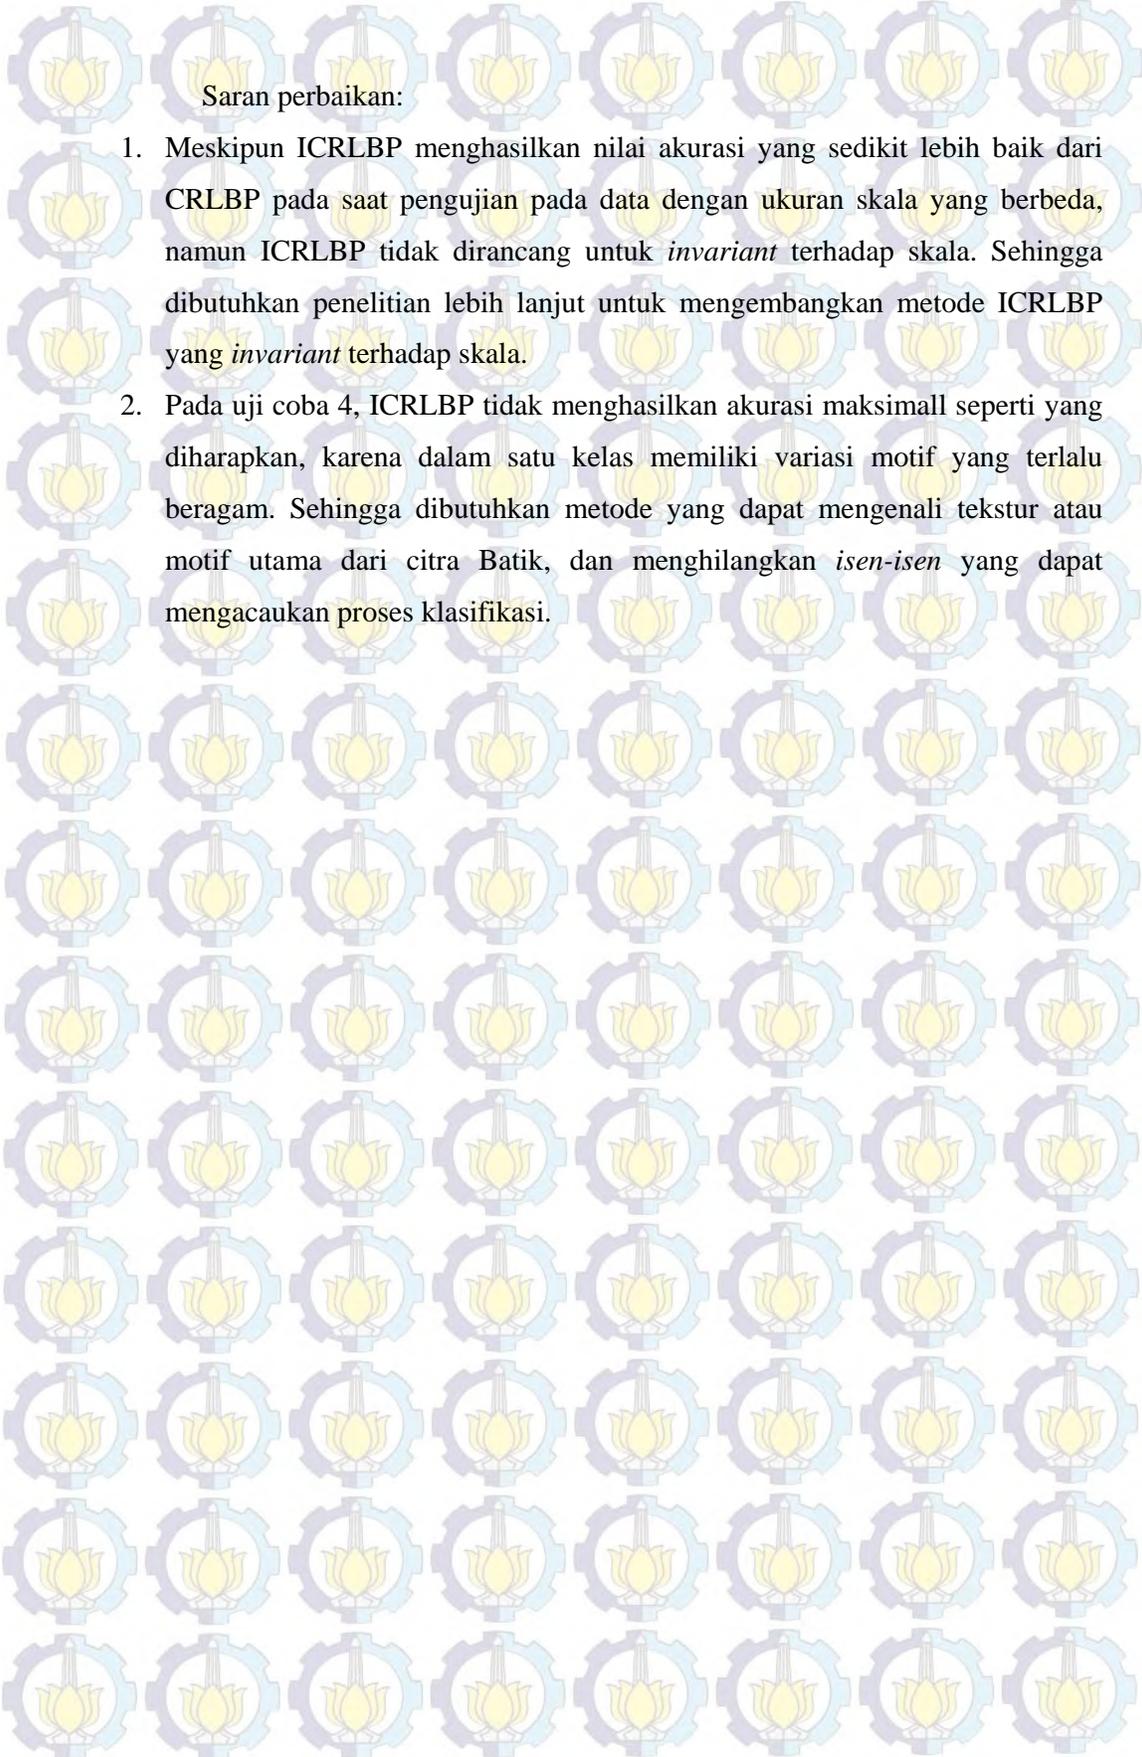
no	Kombinasi ciri	<i>Cross validation</i>					Rata-Rata
1	S	43.48	40.74	33.82	40.10	43.96	40.42
2	M	77.29	87.04	79.23	86.96	83.57	82.82
3	C	32.37	31.02	33.82	28.99	32.85	31.81
4	SM	71.50	78.70	77.29	80.68	78.74	77.38
5	SC	50.72	50.46	43.96	51.21	54.59	50.19
6	MC	71.98	74.07	67.15	82.13	78.26	74.72
7	SMC	71.50	76.39	64.25	78.26	75.85	73.25
8	S_M	60.87	66.67	81.16	82.13	78.74	73.91
9	S_C	82.13	85.65	87.44	90.82	88.89	86.98
10	M_C	90.82	91.20	94.69	97.10	92.27	93.22
11	S_M_C	59.90	56.94	60.39	69.08	66.67	62.60

BAB 5

KESIMPULAN

Berdasarkan uji coba dan analisa hasil, maka dapat ditarik beberapa kesimpulan antara lain:

1. Berdasarkan uji coba 1, kombinasi ciri teroptimal pada metode ICRLBP untuk dataset Batik dan brodatz adalah ICRLBP_M dan ICRLBP_C, dengan metode penggabungan histogram *jointly*. Dengan akurasi 96,14% pada dataset Batik dan 82,13% pada dataset Brodatz.
2. Berdasarkan uji coba 2, akurasi pengklasifikasian dengan metode ICRLBP menurun kinerjanya pada sudut antara 35°-70°, dan akurasi mencapai nilai yang baik pada kelipatan 90°.
3. Berdasarkan uji coba 3, penambahan *replicate padding* ternyata tidak begitu mempengaruhi kinerja ICRLBP. Oleh karena itu, proses *replicate padding* pada metode ICRLBP tidak begitu diperlukan.
4. Berdasarkan uji coba 4, penambahan metode *preprocessing* pada dataset Batik dengan variasi motif pada satu kelas dapat meningkatkan akurasi ICRLBP sekitar 6,17%.
5. Berdasarkan uji coba 5, metode ICRLBP sedikit lebih unggul dibandingkan CRLBP dalam mengenali citra uji dengan berbagai macam ukuran yang berbeda, yaitu sekitar 3,33%.
6. Berdasarkan uji coba 6, metode ICRLBP lebih unggul dibandingkan metode CRLBP dalam mengenali data uji yang dirotasi pada sudut 5°, 10°, 15°, 20°, 25°, 30°, 35°, 40°, 45°, 50°, 55°, 60°, 75°, 80°, 85°, 90°, 135°, 180°, 225°, 270°, dan 315°. ICRLBP dapat meningkatkan akurasi sebesar 17,39% pada dataset Batik dan sebesar 37,20% pada dataset Brodatz.
7. Metode ICRLBP dapat meingkatkan waktu proses klasifikasi sebesar 300 kali lipat dari metode CRLBP, karena metode ICRLBP memiliki ciri yang lebih sedikit dibandingkan metode CRLBP.



Saran perbaikan:

1. Meskipun ICRLBP menghasilkan nilai akurasi yang sedikit lebih baik dari CRLBP pada saat pengujian pada data dengan ukuran skala yang berbeda, namun ICRLBP tidak dirancang untuk *invariant* terhadap skala. Sehingga dibutuhkan penelitian lebih lanjut untuk mengembangkan metode ICRLBP yang *invariant* terhadap skala.
2. Pada uji coba 4, ICRLBP tidak menghasilkan akurasi maksimal seperti yang diharapkan, karena dalam satu kelas memiliki variasi motif yang terlalu beragam. Sehingga dibutuhkan metode yang dapat mengenali tekstur atau motif utama dari citra Batik, dan menghilangkan *isen-isen* yang dapat mengacaukan proses klasifikasi.

DAFTAR PUSTAKA

- Doellah, H. S. (2002). *Batik : Pengaruh Zaman dan Lingkungan*. Solo: Batik Danar Hadi.
- Guo, Z.H., Zhang, L., Zhang, D. (2010). "A completed modeling of local binary pattern operator for texture classification," *IEEE Trans. Image Process.* 19 (6) 1657–1663.
- Hamidin, A.S. (2010). "Batik, Warisan Budaya Asli Indonesia", Penerbit NARASI, Yogyakarta.
- Haake, A. (1989). "The Role Of Symmetry In Javanese Batik Patterns", in *Journal of Computers Math. Applic.* Vol. 17, No. 4-6, pp.815-826. Science Direct.
- Nilogiri A. (2012). "Klasifikasi Kansei Multi Label dengan Probabilistic Neural Network pada Citra Batik menggunakan Kombinasi Ciri Warna, Tekstur, dan Bentuk". Institut Teknologi Sepuluh Nopember, Surabaya.
- Ojala, T., Pietikäinen, M., & Harwood, D. (1996). "A Comparative Study of Texture Measures with Classification Based on Feature Distributions," *Science Direct : Pattern Recognition*, vol. 29, pp. 51-59.
- Ojala, T., Pietikäinen, M., & Mäenpää, T. (2002). "Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns," *IEEE TPAMI*, vol. 24, pp. 971-987.
- Pietikäinen, M., Ojala, T., & Xu, Z. (2000). "Rotation-Invariant Texture Classification Using Feature Distributions," *Science Direct : Pattern Recognition*, vol. 33, pp. 43-52.
- Sipi.usc.edu. (2014). SIPI Image Database - Textures. [online] Retrieved from: <http://sipi.usc.edu/database/database.php?volume=textures> [Accessed: 7 Apr 2014].
- Specht, D.F. (1990). Probabilistic neural networks. *Neural Netw.* 3, 109–118
- Susanto, S. (1980). *Seni Kerajinan Batik Indonesia*. Yogyakarta: Departemen Perindustrian dan Perdagangan.
- Timung S., Mandal T.K. (2013). "Prediction of flow pattern of gas-liquid flow through circular microchannel using probabilistic neural network". *Applied Soft Computing* vol.13 pp. 1674–1685
- Wang J.S., Chiang W.C., Hsu Y.L., & Yang Y.T.C. (2013). "ECG arrhythmia lassification using a probabilistic neural network with a feature reduction method". *Neurocomputing* vol.116 pp.38–45.
- Zhao, Y., Jia, W., Hu, R.X., Min, H. (2013). "Completed robust local binary pattern for texture classification". *Science Direct : Neurocomputing*, vol. 106, pp. 68–76.

BIODATA PENULIS



Penulis lahir di Jogjakarta. Pada tahun 2006 penulis menempuh pendidikan S1 di Universitas Gajah Mada dan melanjutkan kejenjang S2 di Institut Teknologi Sepuluh Nopember Surabaya pada tahun 2012. Penulis dapat dihubungi melalui email : emailkuwardhani@gmail.com