

KLASIFIKASI CITRA BATIK MENGGUNAKAN METODE EKSTRAKSI CIRI YANG INVARIANT TERHADAP ROTASI

Arrie Kurniawardhani¹⁾, Nanik Suciati²⁾, dan Isye Arieshanti³⁾

^{1,2,3)} Jurusan Teknik Informatika, Fakultas Teknologi Informasi

Institut Teknologi Sepuluh Nopember, Surabaya

e-mail: emailkuwardhani@gmail.com¹⁾, nanik@if.its.ac.id²⁾, isye.arieshanti@gmail.com³⁾

ABSTRAK

Untuk membantu proses pendokumentasian citra Batik, dibutuhkan sistem klasifikasi yang cukup handal dalam mengklasifikasi dan mengidentifikasi citra Batik. Salah satu kehandalan sistem klasifikasi yang dibutuhkan adalah invariant terhadap rotasi. Kehandalan tersebut dibutuhkan agar sistem dapat diaplikasikan untuk mengenali citra dari berbagai macam sumber, seperti internet. Kehandalan sistem klasifikasi tidak lepas dari kehandalan metode ekstraksi cirinya. Salah satu metode ekstraksi ciri yang invariant terhadap rotasi adalah LBPROT. Namun, LBPROT memiliki kekurangan yaitu mengabaikan karakteristik lokal dari kontras atau nilai varian. Di lain pihak, Completed Local Binary Pattern (CLBP) dan Completed Robust Local Binary Pattern (CRLBP) memiliki ciri yang dapat merepresentasikan nilai varian lokal tanpa mengabaikan struktur spasial lokal, yaitu ciri magnitude-nya, CLBP_M dan CRLBP_M. Oleh karena itu, pada penelitian kali ini diusulkan metode klasifikasi yang invariant terhadap rotasi, dengan menggunakan metode ekstraksi ciri yang menggabungkan kelebihan metode LBPROT dan CLBP_M (rotCLBP_M), atau LBPROT dan CRLBP_M (rotCRLBP_M). Hasil ekstraksi ciri akan menjadi data masukan untuk sistem klasifikasi Probabilistic Neural Network (PNN). Kinerja sistem diukur menggunakan akurasi. Hasil uji coba menunjukkan bahwa sistem klasifikasi dengan metode ekstraksi ciri rotCRLBP_M, lebih unggul dibandingkan dengan metode rotCLBP_M. Sistem klasifikasi dapat mencapai akurasi maksimal sebesar 90.34% untuk dataset Batik. Sedangkan pada dataset Brodatz, sistem klasifikasi dapat mencapai akurasi sebesar 87,92%.

Kata kunci: Batik, ekstraksi ciri tekstur, LBPROT, probabilistic neural network, rotation invariant.

ABSTRACT

To assist the process of Batik image documentation, a reliable classification system is needed. One of the reliability of the classification system is rotation invariant. That reliability is required in order to recognize images from various sources, such as internet. The reliability of the classification system can not be separated from the reliability of feature extraction method. One of feature extraction method that is rotation invariant is LBPROT (rotation invariant LBP). However, LBPROT has the disadvantage, that is ignores the local feature of the contrast or variance. On the other hand, Completed Local Binary Pattern (CLBP) and Completed Robust Local Binary Pattern (CRLBP) has a feature that can represent the local variance without neglecting the local spatial structure. Those feature are its magnitude, CRLBP_M and CLBP_M. Therefore, in this study we proposed rotation invariant classification system, using a feature extraction that combines the advantages of the method LBPROT and CLBP_M (rotCLBP_M), or LBPROT and CRLBP_M (rotCRLBP_M). The classification method used in this paper is Probabilistic Neural Network (PNN). The classification performance is measured by accuracy. The experimental results show that the classification system with rotCRLBP_M is superior to rotCLBP_M. That classification system can achieve a maximum accuracy of 90.34% for dataset Batik. Whereas for the Brodatz dataset, the classification system can achieve an accuracy of 87.92%.

Keywords: Batik, LBPROT, probabilistic neural network, rotation invariant, texture feature extraction.

I. PENDAHULUAN

BATIK adalah corak atau pola tradisional pada kain yang digambar dengan metode tradisional. Dalam bahasa Jawa, Batik berarti menggambar titik pada kain, karena tersusun dari asal kata “ngembat” (menulis) dan “titik” (titik atau dot) [1]. 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 [2]. Berdasarkan jenis motif dasar dan sifat keteraturan yang menyusun kain Batik, maka Batik dapat diklasifikasikan berdasarkan motif dasarnya untuk membantu proses dokumentasi [3].

Beberapa penelitian telah dilakukan untuk mengekstraksi ciri motif dasar Batik, baik untuk sistem temu kembali citra maupun untuk sistem klasifikasi citra Batik. Minarno dkk [4] menggunakan metode ekstraksi ciri yang disebut *enhanced micro structure descriptor* untuk sistem temu kembali citra Batik berdasarkan konten. Nurhaida dkk [5] menyatakan dalam penelitiannya bahwa *Gray Level Co-occurrence Matrices* (GLCM) merupakan metode ekstraksi ciri yang terbaik untuk mengenali citra Batik, dibandingkan *Canny Edge Detection* dan *Gabor filters*. Minarno dkk [3] menggabungkan metode ekstraksi ciri GLCM dengan *Discrete Wavelet Transform* (DWT), yang diberi nama *Co-Occurrence Matrices of Sub-Band Image* untuk mengklasifikasi motif dasar Batik, dimana dalam satu kelas motif dasar Batik, terdapat berbagai macam cara untuk menggambarkan motif dasarnya.

Namun, beberapa metode yang diusulkan pada penelitian tersebut belum mempertimbangkan kehandalan metode ekstraksi cirinya untuk mengenali citra yang dirotasi pada berbagai macam sudut. Saat ini, metode yang handal dalam mengenali citra yang dirotasi pada berbagai macam sudut atau invarian terhadap rotasi, sangat dibutuhkan agar sistem dapat diaplikasikan untuk mengenali citra pada berbagai macam sumber.

LBPROT [6] adalah salah satu metode ekstraksi ciri yang *invariant* terhadap rotasi. Pietikäinen [6] mengusulkan metode tersebut untuk memperbaiki kinerja metode ekstraksi ciri *Local Binary Pattern* (LBP). LBPROT dapat mengenali citra yang dirotasi pada sudut 90° dengan sangat baik. Namun kemampuannya berkurang pada saat mengenali citra yang dirotasi 30° , 60° , 120° , 150° , dan 200° . Hal ini dapat disebabkan karena ada karakteristik lokal yang diabaikan oleh LBPROT yaitu kontras atau nilai varian. Oleh karena itu, saat LBPROT digabung dengan ciri nilai varian lokal (VAR), peningkatan akurasi dapat dicapai.

Kemudian, Guo [7] mengusulkan metode *Completed Local Binary Pattern* (CLBP) untuk memperbaiki kelemahan LBP yang kurang akurat dalam menggambarkan struktur lokal citra. Beberapa struktur lokal citra yang berbeda dapat memiliki nilai LBP yang sama. Guo menambahkan ciri nilai *magnitude* perbedaan antara piksel pusat dengan piksel tetangga (CLBP_M) dan ciri piksel pusat terhadap keseluruhan nilai intensitas citra (CLBP_C), untuk melengkapi ciri nilai *sign* perbedaan antara piksel pusat dengan piksel tetangga (CLBP_S). Ciri CLBP_S sama dengan LBP. Pada penelitian tersebut Guo menyatakan bahwa kinerja CLBP_M lebih baik dibandingkan ciri VAR dalam menggambarkan nilai varian lokal, karena VAR hanya menggambarkan nilai varian intensitas lokal dengan mengabaikan struktur spasial lokal.

Di lain pihak, Zhao [8] mengusulkan *Completed Robust Local Binary Pattern* (CRLBP). CRLBP juga merupakan metode yang berdasarkan pada LBP. CRLBP diusulkan untuk memperbaiki *Completed Local Binary Pattern* (CLBP), yang sensitif terhadap derau. Apabila terjadi derau, terutama pada pusat piksel pusat dapat mempengaruhi nilai LBP. CRLBP juga terdiri dari 3 ciri seperti CLBP, yaitu CRLBP_S, CRLBP_M, dan CRLBP_C. Perbedaan antara CLBP dan CRLBP adalah nilai *thresholding*-nya. CRLBP tidak langsung menggunakan nilai intensitas pusat sebagai nilai *thresholding*, yang nantinya akan digunakan sebagai pembanding dengan nilai intensitas tetangga. Ciri CRLBP_M juga menggambarkan nilai varian intensitas lokal. CRLBP_M diharapkan dapat lebih baik dari CLBP_M, karena tidak sensitif terhadap derau.

Pada penelitian kali ini, diusulkan sistem klasifikasi yang *invariant* terhadap rotasi, dengan mencari metode ekstraksi ciri yang paling *invariant* terhadap rotasi diantara LBPROT, kombinasi LBPROT dengan CLBP_M, atau kombinasi LBPROT dengan CRLBP_M. Metode klasifikasi yang akan digunakan untuk sistem klasifikasi pada penelitian kali ini adalah *Probabilistic Neural Network* (PNN).

II. BATIK

Batik adalah corak atau pola tradisional pada kain yang digambar dengan metode tradisional. Corak pada kain Batik pada umumnya terdiri atas dua bagian [9]. Bagian pertama adalah *klowongan* atau pola utama. Pola utama merupakan pola dasar yang kemudian akan membentuk suatu kerangka gambar untuk membentuk Batik secara keseluruhan, atau disebut motif [10]. Bagian kedua adalah *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 proses klasifikasi, maka Batik dideskripsikan berdasarkan motif dasarnya. Pengklasifikasian Batik berdasarkan motif dasarnya, dapat dibagi menjadi 2 kelas utama, yaitu motif geometri dan *non-geometri* [9].


Motif geometris adalah motif Batik yang pola dasarnya membentuk bangun geometris tertentu secara berulang dan beraturan. Motif geometris dapat dibagi lagi menjadi beberapa subkelas [2], yaitu Banji, Stensil (*Ceplok, Kawung*), Garis miring (*Udan Liris, Parang*), dan Anyaman (*Nitik*). Motif *non-geometri* adalah motif Batik yang motif dasarnya tidak mengalami perulangan atau motif dasarnya mengalami perulangan namun tidak beraturan. Motif non-geometris dapat dibagi lagi menjadi beberapa subkelas [2], yaitu Semen, Lung-lungan, dan Buketan. Selain kelas geometri dan non-geometris, 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 [2], yaitu Tambal dan Compositon.

III. METODOLOGI

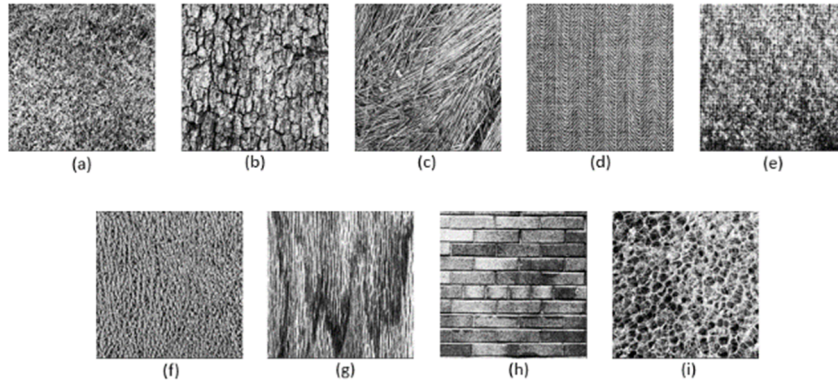
A. Dataset

Data yang digunakan untuk menguji kinerja sistem klasifikasi adalah citra Batik dan citra Brodatz. Citra Batik diperoleh dari buku “Batik: Pengaruh Zaman dan Lingkungan” [9] dan dari menjelajah secara acak di internet. Citra Batik tersebut dikelompokkan menjadi 9 kelas motif dasar Batik, yaitu Banji, Ceplok, Kawung, Tambal, Parang, Udan Liris, Semen, dan Buketan. Ilustrasi dataset Batik ditunjukkan pada Gambar 1.

Dataset Brodatz [11] juga digunakan pada pengujian, karena dataset Brodatz merupakan data tekstur yang sudah umum digunakan oleh sebagian besar penelitian pada kasus ekstraksi ciri tekstur. Dataset Brodatz diperoleh dari www.ee.oulu.fi/research/imag/texture/image_data/image_data/Brodatz32.zip. 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). Ilustrasi dataset Brodatz ditunjukkan pada Gambar 2.



Gambar 1. Data Batik. (a) *Banji*. (b) *Ceplok*. (c) *Kawung*. (d) *Nitik*. (e) *Parang*. (f) *Udan Liris*. (g) *Tambal*. (h) *Semen*. (i) *Buketan*



Gambar 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*

B. Review Singkat Tentang Local Binary Pattern

Local Binary Pattern (LBP) adalah metode analisis tekstur yang menggunakan model statistika dan struktur. Langkah-langkah LBP dalam mengekstraksi ciri diilustrasikan pada Gambar 3. Pertama, 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 4. Intensitas piksel pusat menjadi *thresholding* untuk menyusun nilai LBP di setiap piksel citra.

Bila nilai intensitas piksel pusat lebih besar dibandingkan nilai intensitas piksel tetangganya maka nilai transformasi biner untuk piksel pusat adalah 1. Sebaliknya, bila nilai intensitas piksel pusat lebih kecil dibandingkan nilai intensitas piksel tetangganya maka nilai transformasi biner untuk piksel pusat adalah 0, seperti yang ditunjukkan pada Gambar 3(b).

Nilai biner dari piksel tetangga tersebut disusun, seperti yang ditunjukkan pada Gambar 3(c). Susunan nilai biner tersebut dikonversi ke nilai desimal, dengan cara mengalikan nilai biner dengan bobotnya, seperti yang ditunjukkan pada Gambar 3(c) dan Gambar 3(d). Secara matematika, perhitungan LBP dapat ditulis berdasarkan Persamaan (1).

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

Dimana,


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

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*. Terakhir, histogram disusun, seperti yang ditunjukkan pada Gambar 3(e)


C. LBP yang Invariant Terhadap Rotasi

LBP yang invarian terhadap rotasi (LBPROT) mengekstraksi ciri tekstur seperti yang ditunjukkan pada Gambar 5. Nilai biner yang diperoleh dari hasil ekstraksi ciri tekstur LBP sebelum diubah ke nilai desimal, digeser hingga diperoleh nilai kombinasi biner yang paling kecil. LBPROT dapat ditulis dengan persamaan (2).


$$LBPROT_{P,R} = \min\{ROT(LBP_{P,R}, p)\} \quad (2)$$



Gambar 3. Ilustrasi Proses LBP. (a) Citra asli. (b) Hasil perbandingan dengan fungsi thresholding. (c) Bobot. (d) Hasil perkalian dengan bobot. (e) Histogram ciri LBP



Gambar 4. Operator LBP



Gambar 5. Penggeseran kombinasi nilai biner untuk mencari kombinasi nilai terkecil

D. Completed Local Binary Pattern

Completed Local Binary Pattern (CLBP) mengekstraksi ciri tekstur secara lokal berdasarkan intensitas piksel pusat terhadap nilai intensitas piksel citra secara keseluruhan (CLBP_C) serta perbedaan *sign* (CLBP_S) dan *magnitude* (CLBP_M) intensitas pusat dengan piksel-piksel tetangga (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 dijelaskan pada Persamaan (1). Sedangkan *magnitude* merupakan representasi besarnya nilai perbedaan antara intensitas piksel tetangga dengan intensitas piksel pusat.

Perbedaan lokal dapat dirumuskan seperti Persamaan (3) 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 (1).

$$d_{p,R} = s_{p,R} * m_{p,R}, \begin{cases} s_{p,R} = sign(d_{p,R}) \\ m_{p,R} = |d_{p,R}| \end{cases} \quad (3)$$

Dimana,

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

Kemudian $s_{p,R}$ disusun menjadi *sign vector* $[s_0, s_1, \dots, s_{P-1}]$, dan $m_{p,R}$ disusun menjadi *magnitude vector* $[m_0, m_1, \dots, m_{P-1}]$. Setelah *sign vector* dan *magnitude vector* diperoleh, nilai vektor

tersebut ditransformasi menggunakan operator CRLBP_S untuk *sign vector* dan CRLBP_M untuk *magnitude vector*.

Karena yang digunakan pada penelitian kali ini hanya CLBP_M, maka hanya rumus operator CLBP_M yang akan ditulis. Rumus operator CLBP_M ditunjukkan pada Persamaan (4).

$$CLBP_M = \sum_{p=0}^{P-1} t(m_p, c) 2^{P-1-p} \quad (4)$$

Dimana,

$$t(x, c) = \begin{cases} 1, & x \geq c \\ 0, & x < c \end{cases}$$

P telah dijelaskan pada Persamaan (1), sedangkan m_p adalah nilai *magnitude* perbedaan antara intensitas piksel pusat dengan intensitas piksel-piksel tetangga ke- p ($p = 0, 1, \dots, P - 1$) Sedangkan c adalah nilai *threshold* yang diperoleh dari nilai rata-rata m_p dari seluruh citra. CLBP_M menghitung nilai varian lokal dari intensitas suatu piksel pusat.

Pada citra abu-abu dengan operator LBP, P sama dengan 8, maka diperoleh 256 ciri dari histogram CRLBP_M, yang diperoleh dari 2^8 . Sedangkan, bila operator LBP P sama dengan 16, maka diperoleh 65536 ciri dari histogram CRLBP_M, yang diperoleh dari 2^{16} .

E. Completed Robust Local Binary Pattern

Completed Robust Local Binary Pattern (CRLBP) merupakan perkembangan dari metode CLBP. CRLBP memiliki ide dasar yang sama dengan CLBP dalam mengekstraksi ciri tekstur yang juga digambarkan secara lokal berdasarkan intensitas piksel pusat (CRLBP_C) serta perbedaan *sign* (CRLBP_S) dan *magnitude* (CRLBP_M) intensitas dari piksel tetangga terhadap intensitas piksel pusat (perbedaan lokal).

Perbedaan antara CLBP dan CRLBP adalah nilai *threshold* yang digunakan. Pada CLBP nilai *threshold* yang digunakan adalah intensitas piksel pusat lokal. Sedangkan, pada CRLBP nilai *threshold* yang digunakan adalah nilai rata-rata intensitas piksel tetangga. Nilai *threshold* dihitung menggunakan Weighted Local Gray Level (WLG) atau Persamaan (5).

$$WLG = \frac{\sum_{p=0}^{P-1} I_{p,R} + \alpha I_c}{P + \alpha} \quad (5)$$

Dimana α adalah nilai parameter yang ditentukan oleh *user*, I_c , $I_{p,R}$, P , dan R telah dijelaskan pada Persamaan (1). Sehingga diperoleh operator CRLBP_M yang ditunjukkan pada Persamaan (6).

$$CRLBP_M = \sum_{p=0}^{P-1} s(m_p - c) 2^{P-1-p} \quad (6)$$

Dimana,

$$\begin{aligned} m_p &= |WLG_p - WLG_c| \\ &= \left| \frac{\sum_{i=0}^{P-1} I_{pi,R} + \alpha I_{p,R}}{P + \alpha} - \frac{\sum_{i=0}^{P-1} I_{ci,R} + \alpha I_c}{P + \alpha} \right| \end{aligned}$$

P , $I_{ci,R}$, I_c , $I_{p,R}$, dan R telah dijelaskan pada Persamaan (1), 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 varian lokal dari matrik WLG.

Pada citra grayscale dengan operator LBP P sama dengan 8, maka diperoleh 256 ciri dari

histogram CRLBP_M, yang diperoleh dari 2^8 . Sedangkan, bila operator LBP P sama dengan 16, maka diperoleh 65536 ciri dari histogram CRLBP_M, yang diperoleh dari 2^{16} .

F. Penggabungan Metode LBPROT dengan CLBP_M, dan dengan CRLBP_M

Penggabungan Metode LBPROT dengan CLBP_M, dan dengan CRLBP_M dilakukan dengan cara menyisipkan algoritma LBPROT pada algoritma CLBP_M maupun CRLBP_M. Tidak ada perbedaan cara penyisipan algoritma LBPROT ke algoritma CLBP_M maupun CRLBP_M.

Citra masukan terlebih dahulu diubah ke citra abu-abu. Pada CLBP_M, perbedaan lokal *magnitude* dihitung dari setiap piksel di citra abu-abu. Sedangkan, pada CRLBP_M, perbedaan lokal *magnitude* dihitung dari setiap piksel di matrik WLГ. Matrik WLГ diperoleh dari mentransformasi citra abu-abu dengan menggunakan Persamaan (5). Perbedaan lokal *magnitude* dihitung untuk memperoleh vektor *magnitude*.

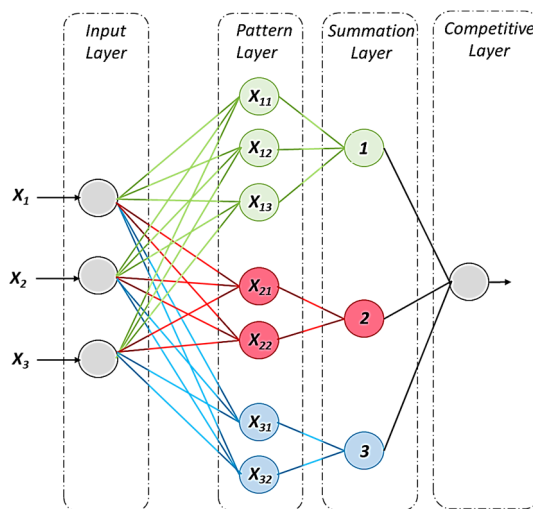
Vektor perbedaan lokal *magnitude* dihitung dengan menggunakan operator CLBP_M, seperti yang ditunjukkan pada Persamaan (4), untuk CLBP_M. Sedangkan untuk CRLBP_M, vektor perbedaan lokal *magnitude* dihitung dengan menggunakan operator CRLBP_M, seperti yang ditunjukkan pada Persamaan (6). Selanjutnya vektor *magnitude* tersebut ditransformasi ke biner. Vektor *magnitude* yang berbentuk biner digeser hingga memperoleh kombinasi nilai biner yang terkecil, seperti algoritma yang digunakan oleh LBPROT. Kemudian, kombinasi biner terkecil tersebut dikonversi ke bilangan desimal. Dari nilai bilangan desimal masing-masing piksel tersebut dibangun histogram ciri.

Pada citra grayscale dengan operator LBP, P sama dengan 8, maka diperoleh 36 dari histogram gabungan antara LBPROT dengan CLBP_M maupun CRLBP_M. Sedangkan, bila operator LBP, P sama dengan 16, maka diperoleh 4116 ciri dari histogram gabungan antara LBPROT dengan CLBP_M maupun CRLBP_M. Gabungan antara LBPROT dengan CLBP_M akan disebut rotCLBP_M, dan gabungan antara LBPROT dengan CRLBP_M akan disebut rotCRLBP_M. Selanjutnya, histogram ciri tersebut akan menjadi data masukkan ke proses klasifikasi.

G. Probabilistic Neural Network

Probabilistic neural network (PNN) merupakan salah satu metode klasifikasi Jaringan Syaraf Tiruan berdasarkan metode *feedforward*. PNN dipilih karena kecepatan operasinya dan keandalannya dalam mengklasifikasi dan mengenali pola [12][13], dan telah diaplikasikan pada klasifikasi *kansei* pada citra Batik [14].

Ide dasar dari PNN diadopsi dari prinsip statistika, Bayes-Parzen. Arsitektur PNN tersusun atas empat lapisan, yaitu *input layer*, *pattern layer*, *summation layer*, dan *decision layer*.



Gambar 6 Arsitektur PNN

Arsitektur PNN ditunjukkan pada Gambar 6. *Input layer* terdiri atas *node-node* masukkan dari vektor ciri. Sehingga, pada *input layer* tidak ada operasi perhitungan.

Pattern layer 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 (7).

$$\varphi_{ki}(x) = \frac{1}{\sqrt{(2\pi)^d} \cdot \sigma^d} \exp\left(-\frac{\|x_i - x_{ki}\|^2}{2\sigma^2}\right) \quad (7)$$

Dimana x_i adalah vektor ciri, x_{ki} adalah data latih, k menunjukkan kelas dari data latih, dan σ adalah *smoothing parameters*. *Summation layer* menghitung penjumlahan dan nilai rata-rata dari keluaran *pattern layer* dari masing-masing kelas, menggunakan Persamaan (8).

$$g_k(x) = \frac{1}{\sqrt{(2\pi)^d}} \cdot \frac{1}{n\sigma^d} \sum_{i=1}^n \exp\left(-\frac{\|x_i - x_{ki}\|^2}{2\sigma^2}\right) \quad (8)$$

Dimana n adalah jumlah dari data latih. *Summation layer* secara tidak langsung menghitung *maximum likelihood* dari vektor ciri.

Competitive layer melakukan perbandingan nilai hasil keluaran *summation layer* dari masing-masing kelas, dengan Persamaan (9). Kemudian memberikan nilai 1 pada kelas mana yang memiliki nilai probabilitas maksimum, dan memberikan 0 pada kelas yang lain.

$$C(x) = \arg \max\{g_k(x)\}, k = 1, 2, \dots, m \quad (9)$$

Dimana m adalah jumlah kelas.

IV. SKENARIO UJI COBA

Untuk melakukan implementasi dan pengujian sistem klasifikasi yang diusulkan menggunakan RRLBP, 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.

A. Analisis Dataset


Pada pengujian sistem klasifikasi yang *invariant* terhadap rotasi, ukuran citra Batik dan citra Brodatz diseragam pada dimensi 128x128 piksel. Pada masing-masing dataset terdiri atas 9 kelas. Masing-masing kelas terdiri atas 6 data latih dan 23 data uji. Enam data latih diperoleh dari *subsampling* satu citra menjadi 6 bagian pada sudut 0°. Contoh keenam citra data latih Batik ditunjukkan pada Gambar 7. Sedangkan contoh keenam citra data latih Brodatz ditunjukkan pada Gambar 8.

Dua puluh tiga data uji diperoleh dari 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°. Contoh citra data uji Batik yang dirotasi ditunjukkan pada Gambar 9. Sedangkan contoh citra data uji Brodatz yang dirotasi ditunjukkan pada Gambar 10.


Dataset Batik yang digunakan untuk pengujian hanya memiliki satu motif dasar Batik dalam satu citra, dan hanya ada satu variasi cara untuk menggambarkan motif dasar Batik dalam satu kelas.

Selain diuji pada data uji yang dirotasi, sistem klasifikasi yang diusulkan juga diuji pada data uji yang diperbesar maupun diperkecil. Tujuan pengujian ini adalah untuk mengetahui kinerja sistem klasifikasi pada data uji yang berbeda ukuran.

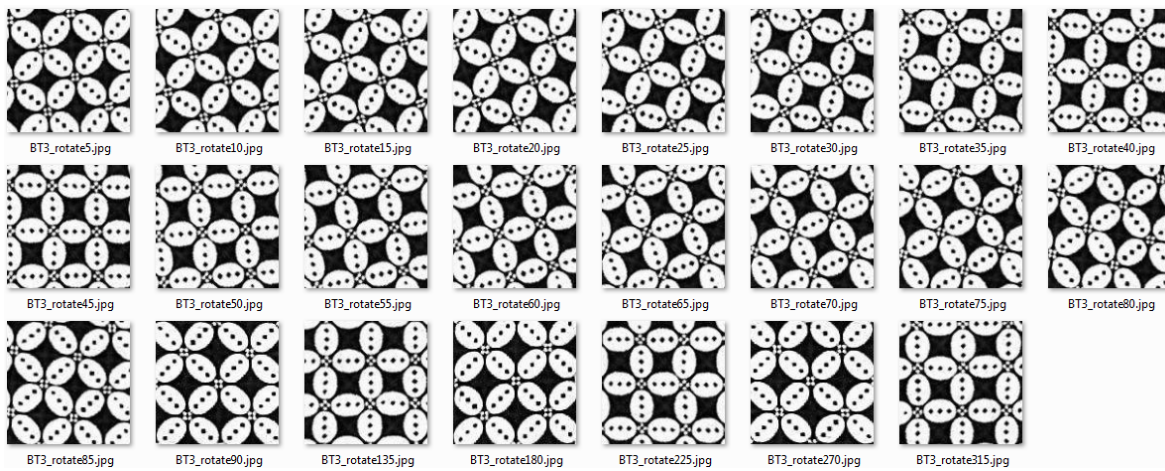
Pada masing-masing dataset terdiri atas 9 kelas. Masing-masing kelas terdiri atas 6 data latih dan 10 data uji. Enam data latih diperoleh dari *subsampling* satu citra menjadi 6 bagian pada sudut 0°, seperti yang ditunjukkan pada Gambar 7 dan Gambar 8. Lima data uji diperoleh dengan memperkecil salah satu citra latih sebesar 90%-50%. Sedangkan, lima data uji sisanya diperoleh



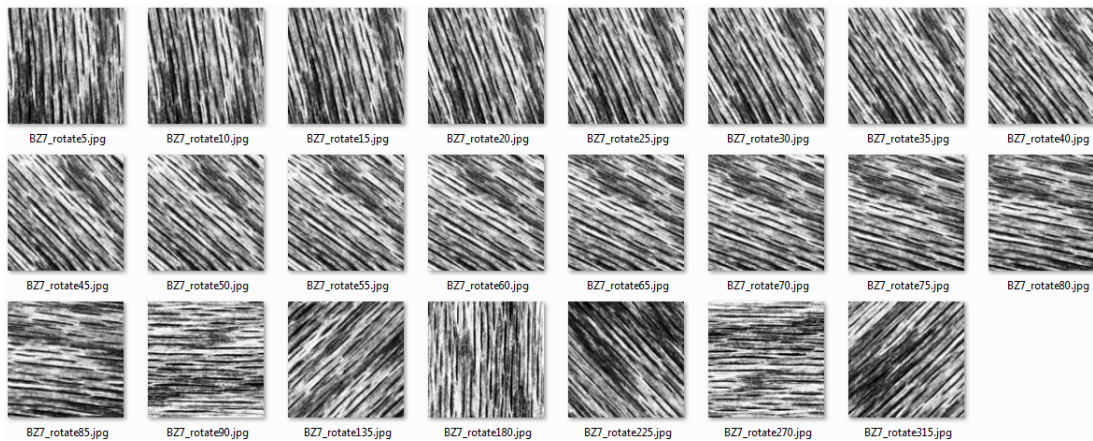
Gambar 7. Citra data latih hasil *subsampling* satu citra Batik



Gambar 8. Citra data latih hasil *subsampling* satu citra Brodatz



Gambar 9. Citra data uji Batik yang dirotasi




Gambar 10. Citra data uji Brodatz yang dirotasi


dengan memperbesar salah satu citra latih sebesar 110%-150%. Contoh citra data uji Batik yang diperbesar 110%-150% dan diperkecil 90%-50% ditunjukkan pada Gambar 11. Sedangkan contoh citra data uji Brodatz yang diperbesar 110%-150% dan diperkecil 90%-50% ditunjukkan pada Gambar 12.

B. Pengujian Perbandingan LBPROT, rotCLBP_M, dan rotCRLBP_M pada Data Uji yang Dirotasi

Pengujian ini dilakukan untuk mengetahui kinerja LBPROT, rotCLBP_M, dan rotCRLBP_M dalam mengekstraksi ciri dari citra yang dirotasi pada berbagai macam sudut. Hal ini dilakukan



Gambar 11. Citra data uji Batik yang di-scale.



Gambar 12. Citra data uji Brodatz yang di-scale.

dengan harapan dapat mengetahui kinerja metode penggabungan yang lebih *invariant* terhadap rotasi diantara *rotCLBP_M*, dan *rotCRLBP_M* dalam berbagai macam variasi data. Sehingga, dapat menjadi metode ekstraksi yang membantu sistem klasifikasi agar *invariant* terhadap rotasi.

C. Pengujian Perbandingan *LBPROT*, *rotCLBP_M*, dan *rotCRLBP_M* pada Data Uji yang Di-scale

Pengujian ini dilakukan untuk mengetahui kinerja *LBPROT*, *rotCLBP_M*, dan *rotCRLBP_M* dalam mengekstraksi ciri dari citra yang diperbesar 110%-150% dan diperkecil 90%-50%. Hal ini dilakukan untuk mengetahui kemampuan kedua metode penggabungan terhadap data dengan ukuran yang berbeda.

D. Pengujian *Cross Validation*

Pengujian *cross validation* dilakukan untuk mengetahui kekonsistenan kinerja sistem klasifikasi dengan metode ekstraksi ciri paling *invariant* terhadap rotasi. Selain itu, pengujian ini juga dilakukan untuk mengetahui pengaruh variasi data latih pada kinerja sistem klasifikasi.

Pengujian *cross validation* dilakukan dengan memvariasi data yang digunakan untuk data latih dan data uji. Variasi tersebut diperoleh dengan cara mengacak data untuk menukar posisi citra sebagai data latih dan data uji. Diharapkan semua data pernah menjadi data latih dan data uji. Pada *cross validation* kali ini, variasi data dilakukan sebanyak 5 kali. Pada setiap variasinya, masing-masing kelas memiliki 6 data latih dan 23 data uji. Kemudian hasil dari proses *cross validation* tersebut dirata-rata untuk memperoleh nilai rata-rata akurasi yang dapat dicapai sistem klasifikasi yang diusulkan.

E. Evaluasi

Terdapat dua aspek penilaian kinerja yang digunakan untuk mengetahui kehandalan sistem klasifikasi yang diusulkan dalam penelitian ini. Aspek pertama adalah akurasi yang dihitung menggunakan rumus yang ada pada Persamaan (10).

$$Akurasi = \frac{n_b}{N} \times 100\% \tag{10}$$

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.

V. HASIL DAN PEMBAHASAN

Hasil pengujian perbandingan kinerja LBPROT, rotCLBP_M, dan rotCRLBP_M dalam mengekstraksi ciri citra dilakukan pada 2 skema. Skema pertama, dengan nilai P=1 dengan R=8. Sedangkan skema kedua, pada P=2 dengan R=16.

A. Hasil Pengujian Perbandingan LBPROT, rotCLBP_M, dan rotCRLBP_M pada Data Uji yang Dirotasi

Hasil pengujian perbandingan kinerja LBPROT, rotCLBP_M, dan rotCRLBP_M dalam mengekstraksi ciri citra yang dirotasi, diukur menggunakan akurasi ditunjukkan pada Tabel I. Tabel I menunjukkan bahwa metode rotCRLBP_M lebih *invariant* terhadap rotasi dibandingkan dengan metode LBPROT dan rotCLBP_M pada kedua dataset dan pada kedua skema, yang ditunjukkan dengan adanya peningkatan akurasi dari metode rotCRLBP_M. Pada dataset Batik peningkatan akurasi tertinggi tercapai pada skema I sebesar 38,16% terhadap LBPROT. Sedangkan pada dataset Brodatz peningkatan akurasi tertinggi tercapai pada skema I sebesar 32,85%. Namun, akurasi tertinggi yang dapat dicapai metode rotCRLBP_M, terjadi pada skema II di kedua dataset, yaitu 90,34% untuk dataset Batik, dan 87,92% untuk dataset Brodatz.

Hal ini menunjukkan bahwa rotCRLBP_M lebih baik dibandingkan rotCLBP_M dalam menggambarkan nilai varian lokal, karena rotCRLBP_M dapat menggambarkan nilai varian intensitas lokal tanpa mengabaikan struktur spasial lokal, dan *insensitive* terhadap derau.

Terjadi *trade off* pada pemilihan skema terbaik. Walau skema II dapat mencapai akurasi tertinggi, namun jumlah ciri pada skema II lebih banyak dibandingkan pada skema I, sehingga dapat berdampak pada lama waktu yang digunakan untuk proses klasifikasi. Skema II memiliki 4116 ciri, sedangkan skema I memiliki 36 ciri.

Pada sebagian besar hasil pengujian, nilai akurasi yang dapat dicapai menggunakan dataset Brodatz selalu lebih rendah dibandingkan dengan nilai akurasi yang dapat dicapai menggunakan dataset Batik. Hal ini disebabkan, karena pada dataset Brodatz tingkat kemiripan satu citra dengan citra lain di kelas yang berbeda lebih tinggi dibandingkan pada dataset Batik.

B. Hasil Pengujian Perbandingan LBPROT, rotCLBP_M, dan rotCRLBP_M pada Data Uji yang Diperbesar

Hasil pengujian kinerja LBPROT, rotCLBP_M, rotCRLBP_M dalam mengekstraksi ciri citra yang diperbesar, diukur menggunakan akurasi ditunjukkan pada Tabel II. Tabel II menunjukkan

TABEL I
AKURASI HASIL PERBANDINGAN LBPROT, rotCLBP_M, DAN rotCRLBP_M PADA DATA UJI YANG DIROTASI

No	Dataset	R=1, P=8			R=2, P=16		
		rotCRLBP_M	rotCLBP_M	LBPROT	rotCRLBP_M	rotCLBP_M	LBPROT
1	Batik	85.99	78.74	47.83	90.34	89.37	71.01
2	Brodatz	71.01	60.87	38.16	87.92	75.85	57.97

TABEL II
AKURASI HASIL PERBANDINGAN LBPROT, rotCLBP_M, DAN rotCRLBP_M PADA DATA UJI YANG DI-SCALE

No	Dataset	R=1, P=8			R=2, P=16		
		rotCRLBP_M	rotCLBP_M	LBPROT	rotCLBP_M	LBPROT	rotCRLBP_M
1	Batik	73.33	73.33	43.33	63.33	63.33	64.44
2	Brodatz	67.78	48.89	55.56	53.33	61.11	62.22

TABEL III
AKURASI HASIL *CROSS VALIDATION* ROTCRLBP_M PADA DATA UJI YANG DIROTASI

No	Dataset	KFOLD (R=1, P=8)					Rata-Rata
		1	2	3	4	5	
1	Batik	81.16	82.61	82.13	81.02	81.16	81.61
2	Brodatz	77.29	87.04	79.23	86.96	83.57	82.82

bahwa metode rotCLBP_M dan rotCRLBP_M dapat meningkatkan akurasi hanya pada dataset Batik dan pada skema I, yaitu sebesar 30%. Metode rotCRLBP_M dapat mencapai akurasi tertinggi pada kedua dataset mengungguli LBPROT hanya pada skema I, yaitu 73,33% pada dataset Batik, dan 67,78% pada dataset Brodatz. Sedangkan pada pengujian lainnya, rotCRLBP_M tidak dapat mengungguli LBPROT.

Hal ini dapat terjadi, karena rotCRLBP_M dan rotCLBP_M tidak dirancang untuk mengekstraksi ciri pada data citra yang memiliki ukuran skala berbeda. Sehingga dibutuhkan metode tambahan yang dapat membantu dalam mengenali motif utama pada dataset citra yang memiliki ukuran skala yang berbeda-beda.

C. Hasil Pengujian Cross Validation

Dari hasil pengujian pada sebelumnya menunjukkan bahwa rotCRLBP_M lebih *invariant* terhadap rotasi dibandingkan dengan rotCLBP_M dan LBPROT. Untuk menguji kestabilan kinerja rotCRLBP_M, maka dilakukan pengujian *cross validation*. Hasil pengujian *cross validation* diukur menggunakan akurasi ditunjukkan pada Tabel III. Akurasi maksimum rata-rata yang dapat dicapai untuk dataset Batik dari hasil *cross validation* adalah 82,82%. Sedangkan pada dataset Brodatz akurasi maksimum rata-rata yang dapat dicapai dari hasil *cross validation* adalah 81,61%. Pada hasil *cross validation* menunjukkan bahwa kedua dataset dapat mencapai akurasi rata-rata yang hampir sama. Hal ini menunjukkan bahwa metode rotCRLBP_M dapat mencapai akurasi sekitar 80% untuk membantu sistem klasifikasi agar *invariant* terhadap rotasi.

D. Lama Waktu Klasifikasi

Aspek kedua untuk menunjukkan kehandalan kinerja metode rotCRLBP_M dibandingkan dengan rotCLBP_M dan LBPROT adalah lamanya waktu yang diperlukan sistem untuk mengklasifikasi citra. Perbandingan kecepatan proses ekstraksi ciri antara rotCRLBP_M, rotCLBP_M, dan LBPROT ditunjukkan Tabel IV. Tabel IV menunjukkan bahwa tidak terjadi perbedaan waktu yang tajam antara proses ekstraksi ciri rotCRLBP_M, rotCLBP_M, dan LBPROT. Perbedaan waktu antara proses ekstraksi ciri rotCRLBP_M dengan LBPROT hanya sekitar 0,0186 detik, sedangkan perbedaan waktu antara proses ekstraksi ciri rotCLBP_M dengan LBPROT hanya sekitar 0,0125 detik.

Begitu pula pada perbandingan kecepatan proses klasifikasi antara metode rotCRLBP_M, rotCLBP_M, dan LBPROT tidak terjadi perbedaan waktu yang tajam. Perbandingan kecepatan

TABEL IV
PERBANDINGAN KECEPATAN PROSES EKSTRAKSI CIRI LBPROT, ROTCLBP_M, DAN ROTCRLBP_M

No	Metode	Waktu (s)
1	LBPROT	0.0164
2	rotCLBP_M	0.0289
3	rotCRLBP_M	0.0350

TABEL V
PERBANDINGAN KECEPATAN PROSES KLASIFIKASII LBPROT, ROTCLBP_M, DAN ROTCRLBP_M

No	Metode	Waktu (s)
1	LBPROT	3.39
2	rotCLBP_M	3.40
3	rotCRLBP_M	3.46

proses klasifikasi antara rotCRLBP_M, rotCLBP_M, dan LBPROT ditunjukkan pada Tabel V. Perbedaan waktu antara proses ekstraksi ciri rotCRLBP_M dengan LBPROT hanya sekitar 0,07 detik, sedangkan perbedaan waktu antara proses ekstraksi ciri rotCLBP_M dengan LBPROT hanya sekitar 0,01 detik.

Hal ini menunjukkan bahwa rotCRLBP_M cukup handal dalam menjadi metode ekstraksi ciri pada sistem klasifikasi yang *invariant* terhadap rotasi, karena dengan perbedaan waktu yang tidak tajam, rotCRLBP_M dapat meningkatkan akurasi sekitar 30%.

VI. KESIMPULAN

Pada penelitian kali ini diusulkan sistem klasifikasi yang *invariant* terhadap rotasi, dengan menggunakan metode penggabungan ekstraksi ciri. Metode penggabungan yang dibandingkan adalah antara LBPROT-CLBP_M (rotCLBP_M) dengan LBPROT-CRLBP_M (rotCRLBP_M). Dari hasil percobaan menunjukkan bahwa sistem klasifikasi dengan metode ekstraksi ciri rotCRLBP_M lebih unggul dibandingkan dengan metode rotCLBP_M. Dengan perbedaan waktu yang tidak tajam, rotCRLBP_M dapat meningkatkan akurasi sekitar 30%, dengan akurasi maksimal sekitar 90%. Hal ini menunjukkan bahwa rotCRLBP_M cukup handal dalam menjadi metode ekstraksi ciri pada sistem klasifikasi yang *invariant* terhadap rotasi.

DAFTAR PUSTAKA

- [1] A.S. Hamidin. *Batik, Warisan Budaya Asli Indonesia*. Yogyakarta, Indonesia : Penerbit NARASI, 2010.
- [2] A. Haake, (1989). The Role Of Symmetry In Javanese Batik Patterns. in *Journal of Computers Math. Applic.* 17(4-6), hal. 815-826.
- [3] A.E. Minarno, Y. Munarko, F. Bimantoro, A. Kurniawardhani, dan N. Suciati. (2014). Texture Feature Extraction Using Co-Occurrence Matrices of Sub-Band Image For Batik Image Classification. *International Conference on Information and Communication Technology (ICoICT)*. [Online]. Bandung, Indonesia. 2, hal. 244-249.
- [4] A.E. Minarno, Y. Munarko, F. Bimantoro, A. Kurniawardhani, dan N. Suciati. (2014) Batik Image Retrieval Based on Enhanced Micro Structure Descriptor. *Asia-Pasific Conference on Computer Aided System Engineering, IEEE-APCASE*. [Online]. Bali: IEEE, hal. 91-96.
- [5] I. Nurhaida, R. Manurung, and A. M. Arymurthy. (2012). Performance comparison analysis features extraction methods for Batik recognition. in *Advanced Computer Science and Information Systems (ICACSIS)*. [Online]. hal. 207-212..
- [6] Pietikäinen, M., Ojala, T., & Xu, Z. (2000). Rotation-Invariant Texture Classification Using Feature Distributions. *Science Direct : Pattern Recognition*. [Online]. 33, hal. 43-52.
- [7] Guo, Z.H., Zhang, L., Zhang, D. (2010). A completed modeling of local binary pattern operator for texture classification. *IEEE Trans. Image Process.* [Online]. 19 (6), hal. 1657-1663.
- [8] Zhao, Y., Jia, W., Hu, R.X., Min, H. (2013). Completed robust local binary pattern for texture classification. *Science Direct : Neurocomputing*. [Online]. 106, hal. 68-76.
- [9] H. S. Doellah. *Batik : Pengaruh Zaman dan Lingkungan*. Solo : Batik Danar Hadi, 2002.
- [10] S. Susanto. *Seni Kerajinan Batik Indonesia*. Yogyakarta : Departemen Perindustrian dan Perdagangan, 1980.
- [11] Sipi.usc.edu. (2014). SIPI Image Database - Textures. [Online] Tersedia: <http://sipi.usc.edu/database/database.php?volume=textures> [diakses : 7 Apr 2014].
- [12] Specht, D.F. (1990). Probabilistic neural networks. *Neural Netw.* [Online]. 3, 109-118.
- [13] 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*. [Online]. 116, hal. 38-45.
- [14] A. Nilogiri, "Klasifikasi Kansei Multi Label dengan Probabilistic Neural Network pada Citra Batik menggunakan Kombinasi Fitur Warna, Tekstur, dan Bentuk," tesis magister, Dept. Teknologi Informasi, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia, 2012.