

Klasifikasi dan Pengenalan Pola Batik Berbasis Ciri Statistis

Indah Soesanti

Jurusan Teknik Elektro dan Teknologi Informasi, FT UGM

Jl. Grafika 2 Yogyakarta

indsanti@gmail.com

Abstract—Texture feature of batik image is a characteristic that can be used for classification the types of batik pattern. This research aims to analyze the performance of classification methods based on statistical feature of the image in order to recognition the batik pattern. Statistical features are obtained based on histogram and Gray Level Co-occurrence Matrices (GLCM). Classification is done by using the Artificial Neural Network Multilayer Perceptron. There are four features extracted from the batik image histogram: mean, variance, energy, and entropy. There are five features extracted from the batik image GLCM: contrast, correlation, energy, entropy, and homogeneity. The result shows that the accuracy of classification with features based on histogram is 90,00% and the accuracy of classification with features based on GLCM is 95,56%.

Keywords- batik; texture; feature extraction; classification; MLP.

Intisari—Ciri tekstur dari citra batik merupakan karakteristik yang dapat digunakan untuk klasifikasi pola batik. Penelitian ini bertujuan untuk menganalisis performa metode klasifikasi berbasis ciri statistis citra untuk pengenalan pola batik. Ciri statistis diperoleh dengan berbasis pada histogram dan Gray Level Co-occurrence Matrices (GLCM). Klasifikasi dilakukan dengan menggunakan Jaringan Syaraf Tiruan Multilayer Perceptron. Terdapat empat ciri yang diekstraksi dari histogram citra batik yakni: mean, varians, energi, entropy. Terdapat lima ciri yang diekstraksi dari GLCM citra batik yakni: kontras, korelasi, energi, entropy, dan homogeneity. Hasil penelitian ini menunjukkan bahwa akurasi klasifikasi dengan ciri berbasis histogram adalah 90,00% dan akurasi klasifikasi dengan ciri berbasis GLCM adalah 96,67%.

Keywords- batik; tekstur; ekstraksi ciri; klasifikasi; MLP.

I. PENDAHULUAN

Batik merupakan salah satu industri asli pribumi yang telah ada sejak dahulu di bumi Indonesia, yang kaya akan corak dan pola batik yang khas [1-2], dan harus dilestarikan keberadaannya. Oleh karenanya sudah menjadi kewajiban bagi seluruh komponen bangsa Indonesia termasuk dari kalangan akademisi untuk menjaga dan melestarikan industri batik yang merupakan warisan nenek moyang Bangsa Indonesia dan merupakan produk unggulan yang mempunyai potensi daya saing tinggi di dunia internasional. Hal ini didukung dengan kenyataan bahwa badan dunia UNESCO telah mengakui bahwa batik merupakan kekayaan milik Bangsa Indonesia.

Untuk membedakan berbagai macam pola batik secara otomatis dapat dilakukan dengan bantuan komputer (*computer aided*). Hal ini didasarkan pada pengambilan ciri yang tepat terhadap batik tersebut, yakni ciri tekstur. Sebenarnya tekstur tersebut merupakan ciri khas yang dimiliki oleh setiap jenis pola, yang bisa membedakannya dengan jenis pola lain.

Tujuan dari penelitian ini adalah menganalisis performa metode klasifikasi berbasis ciri statistis citra untuk pengenalan pola batik. Pada penelitian ini dilakukan ekstraksi ciri statistis terhadap citra batik untuk berbagai macam pola dengan parameter ciri tekstur yang tepat dan melakukan klasifikasi dan pengenalan pola batik berdasar ciri yang telah diperoleh.

II. FUNDAMENTAL

A. Ekstraksi Ciri

Ekstraksi ciri merupakan kegiatan yang penting bagi keberhasilan klasifikasi dan pengenalan pola. Ekstraksi ciri ini dapat dilakukan melalui analisis tekstur. Bharati [3] membagi metode analisis tekstur menjadi empat macam yaitu metode statistis (*statistical method*), metode struktural (*structural method*), metode berbasis model (*model-based method*), dan metode berbasis alihragam (*transform-based method*). Tekstur yang terdapat pada permukaan citra merupakan tekstur alami dan bersifat acak. Untuk tekstur demikian, metode yang sesuai untuk digunakan adalah analisis berdasarkan karakter statistis [4]. Ciri statistis untuk ekstraksi ciri yang dapat digunakan adalah ciri statistis berbasis histogram dan ciri statistis berbasis *Gray Level Co-occurrence Matrices* (GLCM). GLCM ini diperkenalkan oleh Haralick pada tahun 1973 [5].

Metode sederhana untuk mendapatkan tekstur adalah dengan mendasarkan pada histogram. Ciri pertama yang dapat dihitung secara statistis adalah rerata intensitas. Komponen ciri ini dihitung dengan persamaan:

$$m = \sum_{i=0}^{L-1} i \cdot p(i) \quad (1)$$

Dalam hal ini, i adalah aras keabuan pada citra f dan $p(i)$ menyatakan probabilitas kemunculan i dan $L-1$ menyatakan nilai aras keabuan tertinggi. Persamaan (1) di atas akan menghasilkan rerata intensitas citra.

Ciri kedua berupa varians, sesuai dengan persamaan (2). Ciri berikutnya adalah ciri energi, seperti didefinisikan pada persamaan (3).

$$\sigma^2 = \sum_{i=0}^{L-1} (i-m)^2 p(i) \quad (2)$$

$$energi = \sum_{i=0}^{L-1} (p(i))^2 \quad (3)$$

Entropy berkaitan dengan keacakan citra. Semakin tinggi nilai entropi, semakin acak citra tersebut. Entropi juga merepresentasikan jumlah informasi yang terkandung di dalam sebaran data.

$$entropy = -\sum_{i=0}^{L-1} p(i) \cdot \log_2(p(i)) \quad (4)$$

GLCM merupakan matriks bujursangkar berukuran $N \times N$, dengan N adalah jumlah aras keabuan pada citra. Setiap elemen pada matriks tersebut, misal $p[i,j]$ merupakan nilai probabilitas kejadian sebuah piksel bernilai keabuan i bertetangga dengan piksel lain bernilai keabuan j . Kedua piksel tersebut mempunyai jarak d dan arah sudut θ . Jarak paling dekat adalah $d=1$ piksel, sedangkan θ yang digunakan terdiri atas empat sudut yaitu 0° , 45° , 90° , dan 135° .

Ciri atau fitur sebuah citra bisa didapatkan dari GLCM melalui perhitungan. Dari berbagai ciri tersebut, terdapat beberapa ciri yang sering digunakan antara lain sebagai berikut.

1) Kontras (*Contrast*)

$$Contrast = \sum_i \sum_j (i-j)^2 P[i,j] \quad (5)$$

2) Korelasi (*Correlation*)

$$Correlation = \frac{\sum_i \sum_j i \cdot j \cdot P[i,j] - \mu_i \mu_j}{\sigma_i \sigma_j} \quad (6)$$

3) Energi (*Energy*), disebut juga *Angular Second Moment*, atau *Uniformity*

$$ASM = \sum_i \sum_j P^2[i,j] \quad (7)$$

4) Entropi (*Entropy*)

$$Entropy = -\sum_i \sum_j P[i,j] \log P[i,j] \quad (8)$$

5) Homogenitas (*Homogeneity*)

$$Homogeneity = \sum_i \sum_j \frac{P[i,j]}{1+|i-j|} \quad (9)$$

B. Klasifikasi

Terdapat berbagai metode dengan pendekatan yang berbeda untuk melakukan klasifikasi. Misal metode Naïve Bayes, *decision tree*, k-nn, Jaringan Syaraf Tiruan dengan arsitektur *multilayer perceptron* (MLP), dan klasifikasi berbasis logika *fuzzy*. Soria [6] melakukan penelitian mengenai klasifikasi menggunakan metode NBC, C4.5 *decision tree*, dan MLP. Dari ketiga metode tersebut, yang mencapai akurasi tertinggi adalah MLP, selanjutnya NBC, kemudian C4.5. Setsirichok [7] juga membandingkan tiga buah metode tersebut untuk

melakukan klasifikasi karakter darah. Hasil penelitiannya menunjukkan rata-rata akurasi yang dicapai Naïve Bayes dan MLP lebih tinggi daripada C4.5 *decision tree*. Penelitian yang dilakukan Gacquer [8] mendapatkan hasil bahwa dari enam macam metode yang digunakannya, bisa dicatat beberapa hal berikut. MLP memiliki performa paling baik, performansi *fuzzy* lebih rendah dibandingkan metode lain, sedangkan NBC, *decision tree*, dan metode lain mencapai performansi yang hampir sama.

Jaringan Syaraf Tiruan dengan arsitektur MLP merupakan *classifier* yang menggunakan pembelajaran supervised learning, dengan menentukan masukan dan keluaran yang diinginkan. MLP memiliki satu atau lebih lapisan tersembunyi (*hidden layer*) di antara lapisan input (*input layer*) dan lapisan output (*output layer*). Masing-masing lapisan terdiri atas satu atau lebih node. Metode pelatihan MLP yang banyak digunakan untuk klasifikasi dan pengenalan pola adalah propagasi balik (*back propagation*). *Output* didapatkan dengan melakukan perhitungan menggunakan fungsi aktivasi, membandingkan atau menghitung selisih antara hasil keluaran sebenarnya dengan nilai keluaran yang diinginkan, kemudian mengoreksi bobot pada tiap simpul. Proses tersebut dilakukan sampai dengan tercapai kondisi tertentu, yakni jika hasil sudah konvergen dengan ditandai selisih sudah memenuhi syarat, atau cacah *epoch* sudah tercapai.

III. METODOLOGI

A. Alat dan Bahan

Alat yang digunakan pada penelitian ini adalah kamera digital dengan resolusi 12 mega piksel, prosesor, memori, dan perangkat lunak pengolahan citra yaitu Matlab.

Objek penelitian adalah adalah citra berwarna RGB, yang terdiri atas citra batik untuk pola-pola yang akan dikenali yaitu kawung, sido mukti, dan parang. Citra batik ini berukuran 256x256 piksel. Citra batik yang digunakan sejumlah masing-masing 40 citra untuk 3 pola yang berbeda. Citra RGB ini selanjutnya diubah menjadi citra keabuan, sebelum dilakukan proses-proses berikutnya.

B. Langkah-langkah Penelitian

a. Ekstraksi ciri

Sebagai masukan pada langkah ini adalah citra keabuan dengan ukuran 256x256 piksel. Keluaran yang dihasilkan berupa empat ciri statistis berbasis histogram yakni mean, varians, energi, dan *entropy*, serta lima buah nilai ciri berbasis GLCM yakni *contrast*, *correlation*, *energy*, *entropy*, *homogeneity* dari setiap citra.

b. Klasifikasi

Data hasil ekstraksi ciri selanjutnya menjadi input bagi *classifier* yang kemudian akan diklasifikasikan ke dalam tiga kategori yakni batik kawung, sido mukti, dan parang. Metode yang digunakan adalah

Neural Network MLP dengan arsitektur terdiri atas lapisan input, satu *hidden layer*, dan lapisan output.

c. Uji Akurasi

Uji akurasi dilakukan untuk *classifier* yang sama namun dengan ciri yang berbeda, yakni ciri berbasis histogram dan ciri berbasis GLCM. Kedua hasil akan dibandingkan akurasinya sehingga dapat diketahui ciri mana yang tepat untuk klaifikasi pola batik.

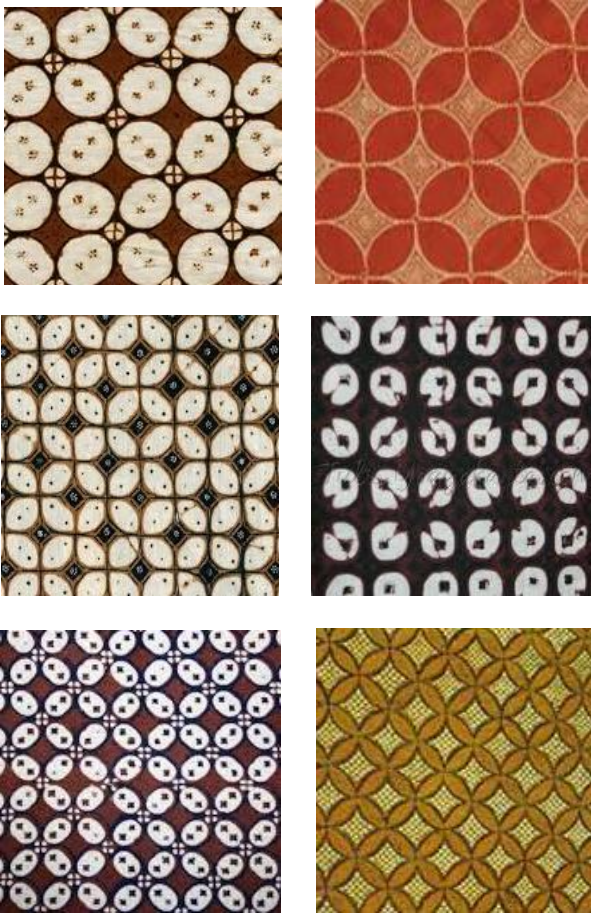
Citra latihan yang digunakan untuk setiap pola adalah sebanyak 10 citra, dan citra uji yang digunakan adalah sebanyak 30 citra. Citra latihan merupakan citra yang dicari cirinya dan digunakan sebagai data latihan bagi Jaringan Syaraf MLP. Dari hasil pelatihan MLP dihasilkan bobot-bobot yang disimpan dan digunakan pada tahap pengujian. Pada tahap pengujian, citra uji diekstraksi cirinya kemudian hasil ekstraksi ciri ini menjadi input bagi MLP untuk menentukan kategori yang tepat bagi tiap citra uji tersebut.

IV. HASIL DAN PEMBAHASAN

Dalam penelitian ini, citra batik diekstraksi cirinya kemudian diklasifikasi berdasar polanya. Ekstraksi ciri ini berguna untuk mengetahui ciri spesifik dari masing-masing pola batik. Data penelitian ini yakni contoh citra batik yang digunakan pada tahap ekstraksi ciri dan klasifikasi citra pola batik ini diperlihatkan pada Tabel 1 sampai Tabel 3.

Citra uji akan diklasifikasikan sebagai salah satu kategori pola batik, yakni sebagai kategori (1) pola batik kawung, atau (2) pola batik sido mukti, atau (3) pola batik parang. Pada Tabel 1 diperlihatkan contoh citra dengan pola Batik Kawung yang digunakan sebagai bahan penelitian. Sedang pada Tabel 2 diperlihatkan contoh data penelitian untuk citra dengan pola Batik Sido Mukti. Pada Tabel 3 diperlihatkan contoh data penelitian untuk citra dengan pola Batik Parang.

Tabel 1. Pola Citra Batik Kawung

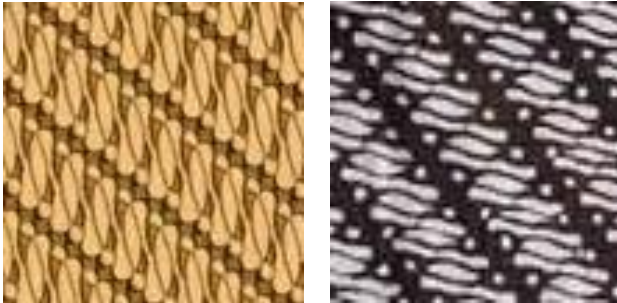

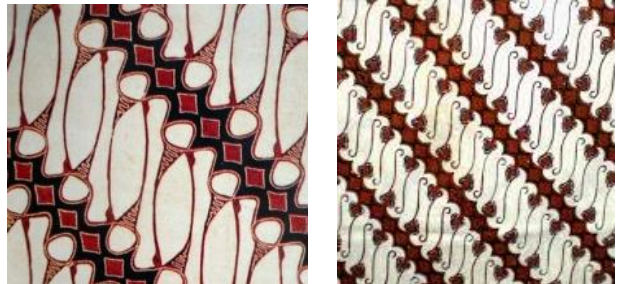

Pola Batik	Citra Batik yang Digunakan
Batik Kawung	



Tabel 2. Pola Citra Batik Sido Mukti

Pola Batik	Citra Batik yang Digunakan
Batik Sido Mukti	

Tabel 3. Pola Citra Batik Parang

Pola Batik	Citra Batik yang Digunakan
Batik Parang	
	
	
	

Hasil pengujian klasifikasi dan pengenalan ciri citra batik ditunjukkan pada Tabel 4. Pada hasil ini diperlihatkan bahwa hasil klasifikasi pola batik dengan menggunakan ekstraksi ciri berbasis histogram citra, yakni ciri mean, varians, energi, dan *entropy* menghasilkan rata-rata akurasi 90,00%.

Hasil klasifikasi pola batik dengan menggunakan ekstraksi ciri berbasis histogram GLCM citra, yakni ciri *contrast*, *correlation*, *energy*, *entropy*, *homogeneity* menghasilkan rata-rata akurasi 95,56%.

TABEL 4. Hasil Akurasi Klasifikasi Pola batik

Pola Batik	Cacah Data Uji	Akurasi Klasifikasi Pola Batik	
		Dengan Ekstraksi Ciri Berbasis Histogram	Dengan Ekstraksi Ciri Berbasis GLCM
Kawung	30	90,00 %	96,67 %
Sido Mukti	30	93,33 %	96,67 %
Parang	30	86,67 %	93,33 %
Rata-rata Akurasi		90,00%	95,56 %

Berdasar hasil pengujian, didapatkan bahwa untuk pola Batik Kawung pada ekstraksi ciri berbasis histogram mempunyai akurasi 90,00%, sedang pada ekstraksi ciri berbasis GLCM mempunyai akurasi 96,67%. Untuk pola Batik Sido Mukti pada ekstraksi ciri berbasis histogram mempunyai akurasi 93,33%, sedang pada ekstraksi ciri berbasis GLCM mempunyai akurasi 96,67%. Untuk pola Batik Parang pada ekstraksi ciri berbasis histogram mempunyai akurasi 86,67%, sedang pada ekstraksi ciri berbasis GLCM mempunyai akurasi 93,33%. Rata-rata akurasi klasifikasi berbasis ciri histogram citra adalah 90,00% dan rata-rata akurasi klasifikasi berbasis ciri GLCM adalah 95,56%. Pola batik yang tidak dapat diklasifikasi secara tepat pada ekstraksi ciri berbasis histogram, dapat diperbaiki dengan ekstraksi ciri berbasis GLCM.

Dari hasil penelitian ini dibuktikan bahwa ekstraksi ciri berbasis GLCM lebih memberikan informasi yang tepat untuk tekstur citra, sehingga dapat digunakan untuk klasifikasi citra dengan akurasi yang tinggi.

V. KESIMPULAN

1. Metode ekstraksi ciri statistis berbasis histogram dan berbasis GLCM, keduanya dapat digunakan untuk ekstraksi ciri tekstur citra batik. Dari kedua metode ini didapatkan bahwa ekstraksi ciri tekstur berbasis GLCM lebih tepat digunakan untuk citra pola batik sehingga menghasilkan nilai akurasi klasifikasi lebih tinggi.
2. Rata-rata akurasi klasifikasi pola batik dengan ekstraksi ciri berbasis histogram 90,00% dan rata-rata akurasi klasifikasi pola batik dengan ekstraksi ciri berbasis GLCM 95,56%.

REFERENSI

- [1] Soesanti, I., A. Susanto, T. Sri Widodo, M. Tjokonagoro, 2009, "Analisis Citra Medis Menggunakan Segmentasi Adaptif", Jurnal JITEE vol 1, Teknik Elektro UGM, Yogyakarta.
- [2] Soesanti, I., T. Sri Widodo, 2013, Klasifikasi Pola Batik Berbasis Ekstraksi Ciri Eigenimage, Annual Engineering Seminar 2013, Yogyakarta.
- [3] Bharati, Manish H., J. Jay Liu, and John F. MacGregor. 2004. "Image Texture Analysis: Methods and Comparisons." *Chemometrics and Intelligent Laboratory Systems*.
- [4] Jain, A. K., 1989. *Fundamentals of Digital Image Processing*. Prentice-Hall, Inc
- [5] Zou, Jian, and Chuan-Cai Liu. 2010. "Texture Classification by Matching Co-Occurrence Matrices on Statistical Manifolds." In *2010 IEEE 10th International Conference on Computer and Information Technology (CIT)*, 1-7.
- [6] Soria, D., J.M. Garibaldi, E. Biganzoli, and I.O. Ellis. 2008. "A Comparison of Three Different Methods for Classification of Breast Cancer Data." In *Seventh International Conference on Machine Learning and Applications, 2008. ICMLA '08*, 619-24.
- [7] Setsirichok, Damrongrit, Theera Piroonratana, Waranyu Wongseeree, Touchpong Usavanarong, Nuttawut Paulkhaolarn, Chompunut Kanjanakorn, Monchan Sirikong, Chanin Limwongse, and Nachol Chaiyaratana. 2012. "Classification of Complete Blood Count and Haemoglobin Typing Data by a C4.5 Decision Tree, a Naïve Bayes Classifier and a Multilayer Perceptron for Thalassaemia Screening." *Biomedical Signal Processing and Control* 7 (2): 202-12.
- [8] Gacquer, D., V. Delcroix, F. Delmotte, and S. Piechowiak. 2011. "Comparative Study of Supervised Classification Algorithms for the Detection of Atmospheric Pollution." *Engineering Applications of Artificial Intelligence* 24 (6): 1070-83.