

PENGENALAN MOTIF BATIK MENGGUNAKAN *ROTATED WAVELET FILTER* DAN *NEURAL NETWORK*

Bernardinus Arisandi, Nanik Suciati, Arya Yudhi Wijaya

Jurusan Teknik Informatika, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember
Kampus ITS Sukolilo, Surabaya

Email : bernard10@cs.its.ac.id, nanik@its-sby.edu, arya@its-sby.edu

ABSTRAK

Batik merupakan kriya tekstil yang menjadi kekayaan intelektual bangsa Indonesia dan telah diakui oleh UNESCO sejak tanggal 2 Oktober 2009. Namun demikian, masyarakat Indonesia sendiri belum banyak yang mengetahui tentang perkembangan dan jenis batik yang merupakan kekayaan budaya tersebut. Pada penelitian ini, dikembangkan sebuah perangkat lunak pengenalan motif batik yang dapat digunakan untuk mengenali motif batik secara otomatis. Fitur tekstur dari citra batik diekstrak menggunakan Rotated Wavelet Transform. Selanjutnya, hasil ekstraksi berupa vektor fitur diklasifikasikan ke dalam motif-motif batik menggunakan metode klasifikasi Neural Network (NN). Uji coba menggunakan dataset testing sama dengan dataset training menghasilkan akurasi tertinggi 100%. Sedangkan uji coba menggunakan dataset testing yang berbeda dengan dataset training menghasilkan akurasi tertinggi 78,26%. Kedua nilai akurasi tersebut didapat pada learning rate 0.8, momentum 0.9, jumlah komposisi node hidden layer [40 10 1], dan level dekomposisi ke-5.

Kata Kunci: pengenalan motif batik, rotated wavelet transform, fitur tekstur, neural network.

1. PENDAHULUAN

Batik adalah sehelai wastra (kain) yang dibuat secara tradisional dan digunakan dalam acara tradisional. Kain tersebut memiliki ragam hias pola batik dan dibuat menggunakan teknik celup rintang dengan malam atau lilin batik sebagai bahan perintang warna [1]. Sedangkan pengertian motif batik adalah suatu kerangka bergambar yang mewujudkan batik secara keseluruhan. Motif batik dapat disebut juga corak batik atau pola batik.

Motif batik terbagi menjadi dua kelompok besar, yakni motif geometri dan non-geometri (lihat Tabel 1). Pada buku Batik Danar Hadi [1], terdapat motif/ pola non geometri yang disebut motif/pola khusus. Motif khusus memuat motif yang tidak dapat dimasukkan ke dalam kelas motif yang lain. Motif ini mempertemukan dua atau lebih motif berbeda yang digabung menjadi satu motif baru.

Beberapa peneliti telah melakukan inventarisasi data batik. Salah satunya dilakukan oleh *Indonesian Archipelago Culture Initiatives* (IACI) [2]. Penyimpanan data batik oleh IACI dikelompokkan berdasarkan daerah asal pembuatan batik sehingga memudahkan pencarian data batik menurut daerah asalnya. Penyimpanan data batik belum dikelompokkan berdasarkan jenis motif batik, sehingga pencarian data batik menggunakan jenis motif masih sulit dilakukan. Pada penelitian ini dikembangkan sebuah perangkat lunak yang dapat mengenali motif batik secara otomatis. Perangkat lunak diharapkan dapat memudahkan pengklasifikasian data batik menurut jenis motif, dan dapat memudahkan masyarakat awam (bukan ahli

batik) untuk mengenali motif kain batik dengan cara memasukkan data citranya sehingga sulit untuk diklasifikasikan. Perangkat lunak yang dibangun dalam penelitian ini dibatasi untuk tidak mengenali batik pola khusus.

Dua hal yang menjadi pertimbangan utama dalam pengembangan perangkat lunak pengenalan motif batik adalah penentuan metode ekstraksi fitur tekstur dan penentuan metode klasifikasi. Dalam penelitian yang dilakukan oleh Manesh Kokare, Biswas, dan Chatterji [3], metode ekstraksi fitur tekstur menggunakan *rotated wavelet transform* memiliki tingkat akurasi sebesar 79% dalam mengenali 116 citra tekstur. Pada buku *Digital Image Processing Using Matlab* yang ditulis oleh Gonzalez, Wood, dan Eddins [4] disebutkan bahwa transformasi *wavelet* lebih handal jika dibandingkan dengan transformasi *fourier* dalam menganalisis citra spasial dan karakteristik frekuensi. Berdasarkan studi literatur tersebut, pada penelitian ini akan digunakan metode *rotated wavelet transform* untuk mengekstrak fitur tekstur dari data citra batik.

Salah satu metode yang bisa digunakan untuk mengklasifikasi data adalah *neural network multi layer perceptron*. Metode tersebut telah berhasil diterapkan pada kasus prediksi time series [5]. Dalam penelitian ini, akan digunakan metode neural network untuk mengklasifikasikan vektor fitur citra batik ke dalam jenis-jenis motif batik.

2. DASAR TEORI

2.1. Transformasi Wavelet

Tabel 1. Penggolongan Motif Batik

Motif Geometri		
Nama Motif	Deskripsi	Contoh Batik
<i>Parang</i>	Pola ini terdiri atas satu atau lebih ragam hias yang tersusun membentuk garis-garis sejajar dengan sudut miring 45°. Terdapat ragam hias berbentuk belah ketupat yang sejajar dengan deretan ragam hias utama pola parang. Ragam tersebut disebut mlinjon.	Parang Barong, Parang Kesit Barong, Parang Surakarta
<i>Ceplok</i>	Motif batik yang didalamnya terdapat gambar-gambar segi empat, lingkaran dan segala variasinya. Gambar-gambar tersebut tersusun secara berulang dan membentuk sebuah pola yang teratur.	Ceplok Indramayu, Sidamukti, dan Sembagen
<i>Lereng</i>	Pada dasarnya sama dengan pola parang, hanya saja tidak memiliki ragam hias mlinjon dan ragam hias gareng.	Liris Cemeng, Lereng Madura, dan Liris Indramayu
Motif Non-Geometri		
<i>Semen</i>	Ragam hias utama yang merupakan ciri pola semen adalah meru. Hakikat meru adalah lambang gunung atau tempat tumbuhan bertunas atau bersemi sehingga motif ini disebut dengan semen, yang diambil dari kata dasar semi.	Semen Rante, Semen Gajah Birawa, Semen Surakarta
<i>Lung-Lungan</i>	Sebagian besar motif lung-lungan mempunyai ragam hias utama serupa dengan motif semen. Berbeda dengan pola semen, ragam hias utama lung-lungan tidak selalu mengandung ragam hias meru.	Alas-alasan Kupu, Lung-lungan Ukel, Lung-lungan Merak
<i>Buketan</i>	Pola buketan mudah dikenali melalui rangkaian bunga atau kelopak bunga dengan kupu-kupu, burung, atau berbagai satwa kecil yang mengelilinginya	Buket Isen Latar, Snow white, Buketan Pekalongan
<i>Pola Khusus</i>	Motif khusus memuat motif yang tidak dapat dimasukkan ke dalam kelas yang lain. Motif khusus mempertemukan dua atau lebih motif lain yang digabung menjadi satu motif baru sehingga sulit untuk diklasifikasikan.	Tambal, Banji, Lung-lungan dengan Lereng

Wavelet adalah fungsi dengan persyaratan matematika tertentu yang mampu melakukan dekomposisi terhadap sebuah fungsi tunggal. *Wavelet* digunakan untuk mendefinisikan ruang multiresolusi [4]. Pada transformasi *wavelet* 2 dimensi digunakan pasangan filter *Low-Pass* atau LPF dan *High-Pass* atau HPF.

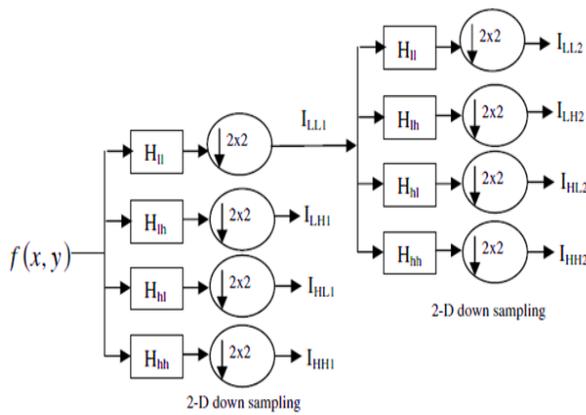
Pasangan filter LPF dan HPF memiliki dua tipe, masing-masing untuk proses dekomposisi dan proses rekonstruksi. Mengacu pada Kokare, Biswas, dan Chatterji [3], filter *wavelet* yang digunakan untuk mengekstraksi fitur adalah filter Daubechies-4. LPF dan HPF pada Daubechies-4 memiliki panjang 8 koefisien. Nilai koefisien dari filter LPF dan HPF untuk proses dekomposisi dapat dilihat pada Tabel 2. Sedangkan proses dekomposisi *wavelet* diilustrasikan pada Gambar 1.

Data masukan $f(x,y)$ berupa matriks citra didekomposisi menjadi empat subbidang domain menggunakan *filter bank*:

1. LL (LPF-LPF), menghasilkan citra aproksimasi.
2. LH (LPF-HPF), menghasilkan citra detil arah horizontal.
3. HL (HPF-LPF), menghasilkan citra detil arah vertikal.
4. HH (HPF-HPF), menghasilkan citra detil arah diagonal.

Tabel 2. LPF dan HPF

L	[-0.2303778133088550.714846570552542 -0.630880767929590 -0.027983769416983 0.187034811718881 0.030841381835987 -0.03288301166698 -0.010597401784997]
H	[-0.01059740178499 0.0328830116669829 0.030841381835987-0.187034811718881 -0.02798376941698 0.630880767929590 0.7148465705525420.230377813308855]



Gambar 1. Proses dekomposisi wavelet

Setiap subbidang merupakan representasi frekuensi terhadap arah yang spesifik. Subbidang ini didapatkan dari hasil konvolusi antara matriks citra dengan filter *wavelet*, yang dilanjutkan dengan proses *downsampling*. Yang terjadi dalam proses *downsampling* adalah penghilangan nilai matriks dengan indeks ganjil dan pengambilan nilai matriks dengan indeks genap.

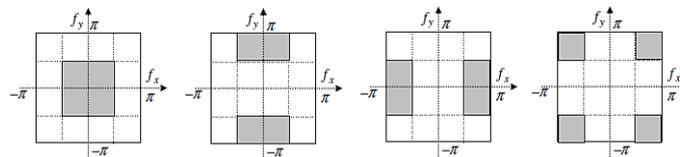
Setiap subbidang dapat dihitung menggunakan persamaan berikut:

$$\begin{aligned}
 \Phi_{j:r,s}(x,y) &= \Phi_{j,r}(x) \Phi_{j,s}(y) \\
 \psi_{j:r,s}(x,y) &= \Phi_{j,r}(x) \psi_{j,s}(y) \\
 \psi_{j:r,s}(x,y) &= \psi_{j,r}(x) \Phi_{j,s}(y) \\
 \psi_{j:r,s}(x,y) &= \psi_{j,r}(x) \psi_{j,s}(y)
 \end{aligned}
 \tag{1}$$

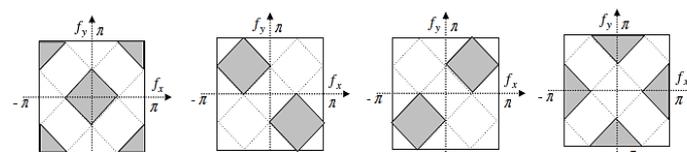
dengan $r, s \in \mathbb{Z}$, dan j adalah level *downsampling*, ψ adalah koefisien tiap *wavelet* induk dan Φ adalah nilai diskrit dari fungsi skala yang didefinisikan pada fungsi 1-D. Pada setiap level dekomposisi, bidang LL didekomposisi menjadi empat subbidang (Gambar 2).

2.2 Rotated Wavelet Filter

Pada *rotated wavelet filter*, filter *wavelet* dirotasi sebesar 45° sehingga domain frekuensi menjadi seperti yang ditunjukkan pada Gambar 3.



Gambar 2. Filter Wavelet Diskrit pada proses dekomposisi level 1



Gambar 3. Filter Wavelet yang dirotasi pada proses dekomposisi level 1

Manesh Kokare dkk [3] membuktikan bahwa penggunaan filter yang dirotasi sebesar 45° memperlihatkan karakteristik motif yang lebih jelas pada setiap bidang hasil dekomposisi.

Berdasarkan hasil penelitian tersebut [3], pada penelitian ini digunakan gabungan dua buah metode transformasi, yaitu *discrete wavelet transform* (DWT) dan *rotated wavelet transform* (RWT). Hasil ekstraksi fitur yang didapat dari gabungan dua metode transformasi tersebut diharapkan akan menghasilkan karakteristik yang lebih baik dibandingkan sebuah metode secara terpisah. Konsekuensi dari penggunaan dua metode transformasi adalah tahap ekstraksi fitur menjadi lebih lama dan panjang fitur menjadi lebih banyak.

2.3 Energi dan Deviasi Standar

Untuk mengidentifikasi motif perlu dihitung terlebih dahulu energi dan deviasi standar dari setiap subbidang hasil transformasi *wavelet*. Perhitungan energi dan deviasi standar bisa dilakukan dengan menggunakan persamaan (2) dan (3).

$$E = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N |X_{ij}|
 \tag{2}$$

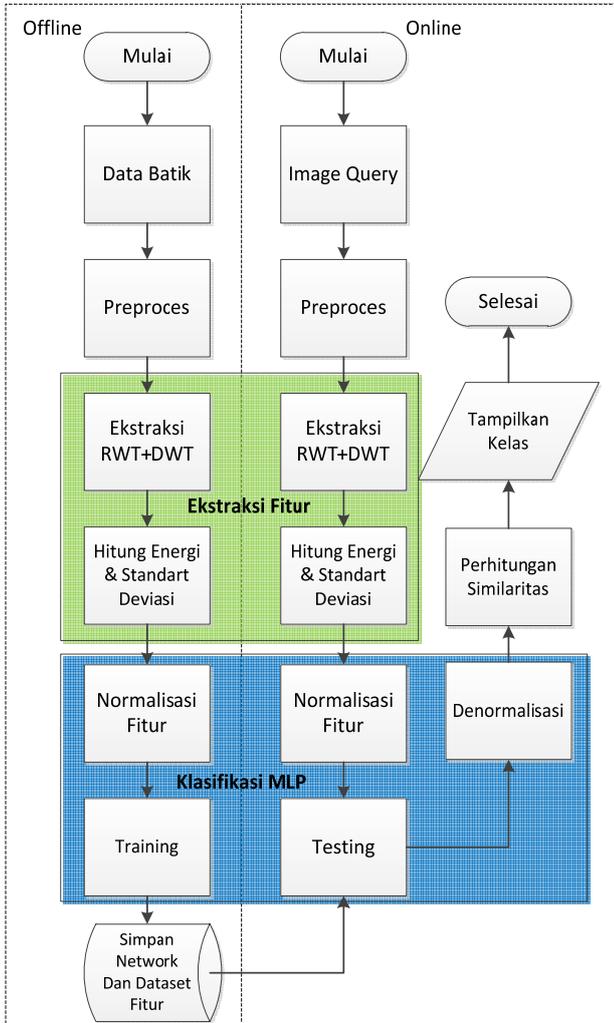
$$Std = \left[\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N (X_{ij} - \mu_{ij})^2 \right]^{\frac{1}{2}}
 \tag{3}$$

$M \times N$ adalah ukuran bidang *wavelet* hasil dekomposisi. $X(i, j)$ adalah koefisien *wavelet* pada setiap bidang dan $\mu(i, j)$ adalah nilai rata-rata dari koefisien *wavelet*.

Nilai energi dan deviasi standar dari setiap bidang hasil dekomposisi *wavelet* merupakan vektor fitur dari setiap citra batik yang selanjutnya dimasukkan ke dalam basis data. Pada setiap level dekomposisi, dihasilkan empat buah subbidang. Pada masing-masing subbidang dihitung energi dan deviasi standar. Jika dekomposisi dilakukan sampai dengan level 5, maka vektor fitur memiliki panjang $((2 \text{ fitur} \times 4 \text{ bidang}) \times 5 \text{ level}) = 40$.

3. PERANGKAT LUNAK PENGENALAN MOTIF BATIK

Diagram alir dari proses pengenalan batik dengan menggunakan *rotated wavelet filter* dan *neural network* ditunjukkan pada Gambar 4.



Gambar 4. Diagram Alir Sistem Pengenalan Motif Batik

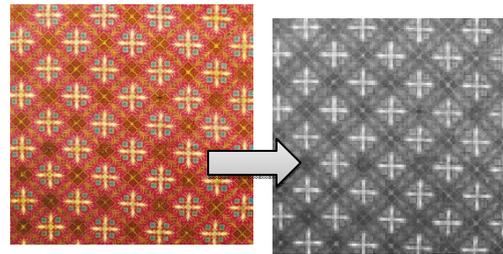
3.1 Dataset

Dataset yang digunakan untuk uji coba berjumlah 228 citra batik, yang terbagi menjadi dataset *training* sebanyak 182 citra dan dataset *testing* sebanyak 46 citra. Terdapat enam buah motif yang berbeda, yaitu parang, semen, lung-lungan, ceplok, lereng, dan buketan. Setiap citra batik di dalam dataset diklasifikasikan ke dalam satu jenis motif batik. Dataset *training* diambil dari koleksi batik di dalam buku Dinar Hadi karangan H. Santosa Doellah (2002) [1]. Sedangkan dataset *testing* diambil dari koleksi batik di dalam buku “Batik” karangan Hamidin A.S. [6].

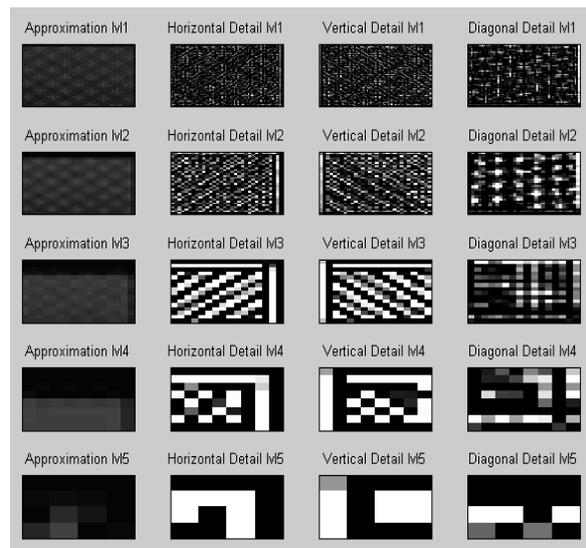
3.2 Preproses

Preproses bertujuan untuk menyiapkan data citra batik agar menjadi lebih seragam sebelum memasuki tahap ekstraksi fitur. Pada tahap preproses dilakukan konversi citra berwarna ke citra keabuan dan merubah ukuran citra menjadi 128 x 128 piksel. Perubahan citra berwarna menjadi citra keabuan dilakukan menggunakan persamaan (4). Contoh preproses citra bisa dilihat pada Gambar 5.

$$grayscale = \frac{red + green + blue}{3} \quad (4)$$



Gambar 5. Contoh Preproses Citra Batik



Gambar 6. Contoh hasil dekomposisi wavelet sampai dengan level 5

3.3 Ekstraksi Fitur

Ada dua tahap utama dalam proses ekstraksi fitur. Pertama, tahap dekomposisi citra menggunakan filter *wavelet*. Kedua, tahap perhitungan energi dan deviasi standar.

Pada tahap dekomposisi dilakukan konvolusi citra dengan filter *wavelet* dan dilanjutkan dengan *downsampling*, yang menghasilkan empat buah sub-citra aproksimasi (LL), detil arah horisontal (LH), detil arah vertikal (HL), dan detil arah diagonal

(HH). Selanjutnya, dilakukan perhitungan energi dan deviasi standar pada setiap sub-citra.

Proses dekomposisi pada level berikutnya dilakukan terhadap sub-citra aproksimasi. Contoh hasil dekomposisi sampai dengan 5 level bisa dilihat pada Gambar 6. Perhitungan nilai koefisien wavelet pada sub-citra aproksimasi M1 pada Gambar 6 menghasilkan energi = 249.055525718299 dan deviasi standar = 65.7555645512. Energi dan deviasi standar dari sub-citra pada setiap level dekomposisi akan menjadi nilai vektor fitur dari citra batik.

Jika dekomposisi dilakukan sampai dengan level 5, maka panjang vektor fitur adalah 40. Jika vektor fitur yang dihitung menggunakan filter *wavelet* diskrit digabung dengan vektor fitur yang dihitung menggunakan filter wavelet yang dirotasi, maka total panjang vektor fitur adalah 80.

3.4 Klasifikasi Multi Layer Perceptron

Dua tahap utama dalam klasifikasi menggunakan *neural network* adalah *training* dan *testing*. Tahap *training* dilakukan menggunakan 182 vektor fitur dari 182 data *training* citra batik. Nilai-nilai di dalam vektor fitur dinormalisasi ke dalam range -1 dan 1.

Metode pelatihan *multi-layer perceptron* dilakukan dengan menggunakan metode penurunan gradien dengan momentum. Dengan adanya momentum, perubahan bobot tidak hanya didasarkan pada *error* yang terjadi setiap 1 iterasi, tetapi juga dengan memperhitungkan perubahan bobot dari iterasi sebelumnya. Sehingga diharapkan bisa mempercepat iterasi. Hasil dari pelatihan disimpan dalam bentuk `.mat` sehingga konfigurasi bobot bisa langsung digunakan pada saat pengetesan.

Secara teori, jaringan dengan sebuah *hidden layer* sudah cukup bagi MLP untuk mengenali pasangan *input* dan target. Akan tetapi, penambahan jumlah *hidden layer* seringkali membuat pembelajaran menjadi lebih efektif, walaupun dengan waktu yang lebih lama. Dalam penelitian *Texture Classification by Wavelet Packet Signatures*[7], jumlah *hidden layer* yang disarankan adalah tiga *hidden layer*.

3.5 Similaritas dan Akurasi

Data keluaran yang dihasilkan dari sistem adalah nama motif dari suatu citra batik input, apakah termasuk dalam kelas parang, semen, lung-lungan, ceplok, lereng, atau buketan. Data keluaran yang kedua adalah nilai similaritas citra yang merupakan hasil penghitungan jarak antara prediksi kelas hasil NN dengan nilai kelas yang terdekat dengan rumus *fuzzy similarity*.

Penghitungan akurasi sebagai tolak ukur evaluasi dalam sistem dapat diperoleh dengan menggunakan rerata pengenalan seperti pada persamaan (5).

$$\text{Rerata Pengenalan} = \frac{\sum_{\text{correct}}}{\sum_{\text{testing}}} \times 100\% \quad (5)$$

4. UJI COBA DAN EVALUASI

Uji coba dilakukan dengan empat skenario, yaitu uji coba untuk mengetahui pengaruh *learning rate*, momentum, komposisi node, dan level dekomposisi. Tabel 3 memberikan rangkuman hasil uji coba yang dilakukan pada pengaruh *learning rate*. Nilai optimal diperoleh pada *learning rate* 0,8 dengan nilai akurasi 96,15% untuk data *testing* sama dengan data *training* dan 50% untuk data *testing* berbeda dengan data *training*.

Tabel 3. Evaluasi dengan Uji Coba Pengaruh *Learning Rate*

Learning Rate	Akurasi dataset training	Akurasi dataset testing	Waktu (Detik)
0,1	79,67%	41,30%	28
0,5	86,26%	45,65%	36
0,8	96,15%	50%	30

Tabel 4. Evaluasi dengan Uji Coba Pengaruh Momentum

Momentum	Akurasi dataset training	Akurasi dataset testing	Waktu (Detik)
0,1	93,9%	43,47%	27
0,5	97,8%	54,3%	25
0,9	100%	78,26%	28

Semakin besar *learning rate* maka rentang untuk menentukan perubahan bobot dalam *neural network* semakin besar dan berpengaruh dengan kedekatan fitur kepada kelas yang lain. Jika *learning rate* kecil maka perubahan bobot semakin kecil dan kedekatan pola ke kelas lain dari inisial target juga semakin jauh. Dari hasil uji coba terlihat bahwa *learning rate* optimal adalah 0,8. Hal ini berarti bahwa pola nilai pada fitur dataset memiliki rentang yang hampir sama sehingga pola fitur semakin sulit dikenali jika hanya menggunakan *learning rate* yang kecil.

Uji coba kedua dilakukan untuk mencari nilai momentum yang menghasilkan nilai akurasi terbesar dengan mengaplikasikan nilai *learning rate* yang diperoleh pada uji coba pertama. Pengaruh momentum pada akurasi aplikasi ditunjukkan pada Tabel 4. Nilai akurasi terendah dihasilkan pada momentum 0,1 dan nilai akurasi tertinggi pada momentum 0,9.

Proses pembelajaran MLP dengan variasi momentum digunakan selain untuk mempercepat

proses *training* juga digunakan untuk mencapai akurasi yang optimal namun dengan melihat keseimbangan nilai *learning rate* dan momentum. Pada percobaan sebelumnya, dengan menggunakan nilai *learning rate* yang sama dan momentum yang berbeda, dihasilkan nilai akurasi yang berbeda. Hal ini membuktikan bahwa hasil optimal dari sistem tidak hanya dipengaruhi oleh nilai *learning rate* saja. Penambahan momentum dilakukan untuk menghindari perubahan bobot yang mencolok akibat data fitur yang sangat berbeda. Apabila beberapa data fitur terakhir yang dimasukkan pada *neural network* memiliki pola yang jauh berbeda, maka perubahan bobot yang dilakukan semakin kecil. Nilai momentum berbanding lurus dengan akurasi.

Uji coba ketiga dilakukan untuk mencari komposisi jumlah *node* yang menghasilkan nilai akurasi yang tertinggi dengan mengaplikasikan nilai *learning rate* yang diperoleh pada uji coba pertama dan momentum yang diperoleh pada uji coba kedua. Komposisi jumlah *node* yang dipakai adalah [160 80 1], [80 10 1], dan [40 10 1]. Komposisi tersebut digunakan untuk jumlah *node* di setiap *layer* pada *hidden layer*. Pengaruh jumlah *node hidden layer* terhadap akurasi aplikasi ditunjukkan pada Tabel 5.

Nilai akurasi tertinggi diperoleh pada komposisi [40 10 1]. Berdasar pada *Analysis Of Hidden Nodes For Multi-Layer Perceptron Neural Networks* [8], tidak ada kepastian tentang berapa banyak jumlah *node* yang paling optimal. Dalam *neural network*, jumlah *node* bergantung pada keunikan pola setiap dataset.

Tabel 5. Evaluasi dengan Uji Coba Pengaruh Jumlah Node

Jumlah Node	Akurasi dataset training	Akurasi dataset testing	Waktu (Detik)
[160 80 1]	13,7%	15,2%	72
[80 10 1]	67,58%	47,3 %	32
[40 10 1]	100%	78,26%	28

Tabel 6. Evaluasi dengan Uji Coba Pengaruh Level Dekomposisi

Level Wavelet	Akurasi dataset training	Akurasi dataset testing	Waktu (Detik)
Level 5	100%	78,26%	28
Level 4	79,12%	54,34%	26
Level 3	68,7%	47,8%	23

Uji coba terakhir dilakukan untuk mengevaluasi level dekomposisi terbaik yang dapat diaplikasikan pada sistem ini. Pada Tabel 6 ditunjukkan bahwa level dekomposisi terbaik diperoleh pada level 5. Hasil ini membuktikan bahwa kesimpulan dari penelitian Manesh Kokare, P.K. Biswas, B.N. Chatterji [3] dapat juga diaplikasikan pada pengenalan motif batik.

Dari keseluruhan uji coba diperoleh akurasi tertinggi 100% untuk data *testing* data sama dengan data *training* dan 78,26% untuk data *testing* berbeda dengan data *training*. Akurasi tertinggi tersebut didapat pada nilai *learning rate* 0,8; momentum 0,9; komposisi *node hidden layer* [20 10 1], dan level dekomposisi ke-5.

5. KESIMPULAN DAN SARAN

Pada penelitian ini telah dikembangkan sebuah aplikasi untuk mengenali motif batik secara otomatis. Dari uji coba yang telah dilakukan dapat disimpulkan bahwa proses ekstraksi fitur tekstur citra batik menggunakan transformasi *wavelet* yang diputar, dan proses klasifikasi menggunakan *multilayer perceptron* memberikan hasil yang cukup baik dalam mengenali motif citra batik.

Saran-saran untuk pengembangan penelitian ini sebagai berikut:

1. Penggunaan data citra batik yang lengkap dari dinas kebudayaan dan pariwisata nasional.
2. Adanya proses seleksi untuk motif batik yang memiliki unsur modern atau pola khusus yang tidak dapat diklasifikasi berdasarkan kerumitan motif.
3. Pengembangan aplikasi ke sistem pengenalan isen-isen dalam batik yang juga mempengaruhi definisi dari setiap motif tidak hanya dibedakan dengan melihat pola batik tapi juga ragam hias yang mengisi di dalamnya.
4. Penelitian lebih lanjut untuk menggunakan algoritma *training neural network* yang lain seperti algoritma *Lavenberg Marquard* (TRAINLM) dan *Gradient Descent with Adaptive learning rate backpropagation* (TRAINGDA).

6. DAFTAR PUSTAKA

- [1] H. Santosa Doellah. 2002. Batik : Pengaruh Zaman dan Lingkungan. Batik Danar Hadi Solo.
- [2] IACI (Indonesian Archipelago Culture Initiatives).Motif dari kawasan Jawa. Juni 2011. <URL:http://www.budaya-indonesia.org/iaci/Daftar_Motif_Pakaian>
- [2] Manesh Kokare, P.K. Biswas, B.N. Chatterji. 2007. Texture Image Retrieval Using Rotated

- Wavelet Filters. Department of Electronics and Electrical Communication Engineering, Indian Institute of Technology, India.
- [4] Gonzalez, Wood dan Eddins. 2004. Digital Image Processing Using Matlab. Prentice Hall.
- [5] Teo, K.K., Wang, L., Lin, Z.. 2001. Wavelet Packet Multi-layer Perceptron for Chaotic Time Series Prediction: Effects of Weight Initialization. School of Electrical and Electronic Engineering Nanyang Technological University.
- [6] Hamidin A.S..2010. Batik : Warisan Budaya Asli Indonesia. Narasi Yogyakarta.
- [7] Andrew Laine dan Jian Fan. 1993. "Texture Classification by Wavelet Packet Signatures" IEEE Transactions On Pattern Analysis And Machine Intelligence, Vol. 15, No. 11.
- [8] Chang Jou, Shih-Shien You, Long-Wen Chang.1994. Analysis Of Hidden Nodes For Multi-Layer Perceptron Neural Networks. Department of Computer Science, National Tsing Hua University, Hsinchu, Taiwan.