



Komparasi Metode Klasifikasi Batik Menggunakan Neural Network Dan K-Nearest Neighbor Berbasis Ekstraksi Fitur Tekstur

Badroe Zaman¹, Ahmad Rifa'i², Mohammad Burhan Hanif³

^{1,2,3}Fakultas Teknologi Informasi dan Komunikasi, Universitas Semarang, Semarang, Indonesia
Email: ¹ badroezaman@usm.ac.id, ² rifai@usm.ac.id, ³ hanifburhan@usm.ac.id

Abstract

Batik tulis adalah hasil seni budaya yang memiliki keindahan visual dan mengandung makna filosofis pada setiap motifnya. Batik tulis memiliki motif yang sangat beragam dan memiliki tingkat kompleksitas yang tinggi sehingga menjadi kesulitan tersendiri dalam pengelompokan kelas batik tertentu. Klasifikasi citra ke dalam kelas tertentu juga menjadi permasalahan yang pelik dalam bidang pengenalan pola. Metode *machine learning* dapat digunakan untuk mengenali kelas batik melalui pengenalan citra batik. Namun belum banyak penelitian terkait studi komparasi klasifikasi citra batik. Sehingga penelitian ini berfokus pada data set citra batik tulis yang menggunakan dua motif yaitu motif klasik dan motif kontemporer. Pada penelitian ini, fitur ekstraksi menjadi dasar klasifikasi dengan metode *Backpropagation Neural Network* dan *k-Nearest Neighbor*. Tujuan dari penelitian ini untuk menemukan pola baru dalam data dengan menghubungkan pola data yang sudah ada dengan data yang baru. Selanjutnya, penelitian ini melakukan perbandingan metode klasifikasi antara *Backpropagation Neural Network* dan *k-Nearest Neighbor* untuk mencari metode klasifikasi terbaik untuk klasifikasi Batik tulis Bakaran. Hasil dari studi komparasi menunjukkan bahwa metode *Backpropagation Neural Network* memperoleh nilai akurasi 90,11% sedangkan metode *k-Nearest Neighbor* mendapatkan nilai akurasi 96,00%. Sehingga dapat disimpulkan bahwa metode *k-Nearest Neighbor* merupakan metode terbaik untuk klasifikasi citra batik.

Keywords: Batik Tulis, Ekstraksi Fitur Tekstur, *Backpropagation Neural Network*, *K-Nearest Neighbor*, Klasifikasi

1. PENDAHULUAN

Batik merupakan salah satu warisan budaya dan identitas nasional yang telah diakui oleh UNESCO (*United Educational, Scientific, and Culture Organization*) [1]. Motif batik dihasilkan dari seni budaya yang memiliki keindahan visual dan mengandung makna filosofis. Seiring sejalannya waktu, motif batik berkembang menurut waktu, tempat dan peristiwa yang menyertai, serta berkembangnya kebutuhan masyarakat. Batik tulis Bakaran dihasilkan dari dua Desa Bakaran sebagai penghasil batik yaitu Desa Bakaran Wetan dan Desa Bakaran Kulon yang berada di wilayah Kecamatan



Juwana Kabupaten Pati, Jawa Tengah. Batik tulis Bakaran memiliki ciri khas motif batik tulis yaitu klasik dan kontemporer. Motif dasar pada suatu kain batik secara keseluruhan digambarkan dengan jenis pola yang disusun secara berulang. Keberulangan motif batik dapat disusun secara teratur maupun tidak teratur. Motif batik tulis yang beragam menjadikan kompleksitas dalam hal pengenalan pola citra batik [2].

Pengenalan pola citra batik telah dilakukan oleh beberapa peneliti terdahulu seperti yang telah dilakukan oleh luh dan sri menggunakan tahapan *pre-processing* ekstraksi fitur *Geometric Moment Invariant* berbasis klasifikasi *k-Nearest Neighbor* (k-NN) yang menghasilkan nilai akurasi 80% lebih tinggi dibandingkan dengan tahapan *pre-processing* ekstraksi fitur *Co-occurrence Matrix* berbasis klasifikasi *k-Nearest Neighbor* yang hanya menghasilkan akurasi sebanyak 70% [3]. Penelitian yang sama dilakukan oleh dhian et al menggunakan algoritma klasifikasi k-NN untuk menentukan kelas batik yang di dahului dengan tahapan *pre-processing* ekstraksi fitur dengan membandingkan transformasi wavelet *daubechies* level 4 (DB-4) dan transformasi wavelet *gabor* dengan hasil yang dicapai transformasi wavelet *daubechies* berbasis k-NN sebesar 100% sedangkan transformasi wavelet *gabor* berbasis k-NN sebesar 54,67% [4]. Penelitian berikutnya dilakukan oleh Prahudya dan Harjoko tentang tahapan *pre-processing* ekstraksi fitur warna dan tekstur pada pengolahan citra dengan masukan 7 fitur ekstraksi yaitu rata-rata nilai RGB (*Red, Green, Blue*), luas cacat, dan nilai GLCM (*energy, homogeneity, dan contrast*) dengan keluaran 4. Sedangkan metode klasifikasi yang digunakan yaitu k-NN yang memberi peningkatan akurasi sebesar 91,25% dengan nilai $k=3$ [5].

Pada tahun berikutnya penelitian dilakukan oleh minamo et al melakukan penelitian tentang komparasi dari metode klasifikasi citra batik menggunakan *Multi Texton Histogram* sebagai tahapan *pre-processing* ekstraksi fitur. Sedangkan algoritma klasifikasi yang diterapkan yaitu k-NN yang menghasilkan nilai akurasi sebesar 82% dan *Support Vector Machine* menghasilkan akurasi sebesar 76% dengan pengujian yang dilakukan menggunakan 300 citra yang terbagi menjadi 50 kelas dan nilai $k=5$ pada algoritma k-NN [6]. Peneliti lain dilakukan oleh achmalia et al berfokus pada komparasi metode klasifikasi *Backpropagation Neural Network* (BPNN) dan *Recurrent Neural Network* (RNN) dimana nilai akurasi terbaik dicapai oleh model klasifikasi BPNN dengan besar nilai akurasi sebanyak 87,97 % [7]. Penelitian terkini tentang citra batik bakaran dilakukan juga oleh zaman et al berfokus pada tahap *pre-processing* ekstraksi fitur menggunakan transformasi wavelet yang memiliki lebih dari satu filter dan di klasifikasikan dengan metode algoritma *Neural Network*. Dalam penelitian ini dicapai bahwa filter *bior5.5* menghasilkan akurasi sebesar 80,77% lebih tinggi dibandingkan filter *coif2* yang hanya menghasilkan akurasi sebesar 78,85% [8].


Berdasarkan penelitian terkait dalam klasifikasi citra dapat dilihat bahwa kombinasi antara tahapan *pre-processing* dengan metode klasifikasi yang tepat akan

menghasilkan nilai akurasi serta ketepatan dalam pemilihan klasifikasi yang lebih baik. Maka klasifikasi citra dalam penelitian ini diawali dengan tahapan *pre-processing* berupa ekstraksi fitur yang akan digunakan sebagai deskripsi untuk membedakan motif pada citra batik. Metode ekstraksi fitur dapat dilakukan dengan baik berdasarkan pendekatan statistik atau spektrum. *Gray Level Co-Occurrence Matrices* (GLCM) adalah metode ekstraksi fitur yang menggunakan perhitungan statistik didasarkan pada nilai piksel citra asli dan hubungan ketetanggaan antara dua piksel pada jarak dan orientasi sudut tertentu. Sedangkan transformasi wavelet merupakan metode ekstraksi tekstur berdasarkan pendekatan spektrum. *Discrete Wavelet Transform* (DWT) secara umum merupakan dekomposisi citra pada frekuensi citra *sub-band* tersebut yang hasil luaranya akan dimasukkan kedalam metode klasifikasi batik [6].

BPNN dan k-NN adalah metode algoritma yang termasuk dalam kelas *supervised learning* dimana tujuan dari kelas *supervised learning* yaitu untuk menemukan pola baru dalam data dengan menghubungkan pola data yang sudah ada dengan data yang baru. Namun kedua algoritma ini mempunyai keunggulan dan kelemahan nya masing-masing sehingga perlu dilakukan penelitian untuk mendapatkan algoritma yang terbaik dalam pemilihan kelas citra batik. Oleh karena itu pada penelitian ini akan dijelaskan hasil dari komparasi metode klasifikasi antara BPNN dan k-NN untuk mencari metode klasifikasi terbaik dalam klasifikasi Batik tulis Bakaran.

2. METODE

Metode BPNN dan k-NN digunakan untuk mengklasifikasi motif citra batik. Pada penelitian ini menggunakan ekstraksi fitur tekstur untuk klasifikasi citra batik tulis. *Pre-processing* dilakukan untuk meningkatkan performansi citra asli dataset. Gambar 1 menunjukkan alur dari klasifikasi motif citra batik.



Gambar 1. Alur Penelitian

2.1. Dataset

Data citra pada penelitian ini, diambil dari beberapa tempat pengrajin batik tulis Bakaran. Data citra batik tulis yang digunakan adalah data privat dengan jenis motif yaitu motif klasik dan motif kontemporer. Data dikelompokkan ke dalam 2 jenis data yaitu data *training* dan data *testing*. Sebanyak 450 citra batik tulis motif klasik dan 450 citra batik motif kontemporer digunakan untuk data *training* dan data *testing*. Data sebanyak 20% dari jumlah setiap jenis motif akan digunakan untuk data *testing* dan sisanya untuk data *training*. Contoh dataset dapat dilihat pada Tabel 1 contoh citra batik berdasarkan motif.

Tabel 1. Contoh Citra Batik Berdasarkan Motif



2.2. Pre-Processing

Beberapa tahapan dalam *pre-processing* untuk data *training* dalam penelitian ini. Pertama, citra awal di *resize* dengan skala 0,25 dalam skala faktor 0 – 1 dari citra awal. Kedua, dilakukan *cropping* [9] [10] untuk mendapatkan pola primitif dan contoh pola tekstur dari citra batik tulis dengan ukuran resolusi 512x512 piksel. Terakhir, citra RGB dikonversi ke *Red Channel*. Pada umumnya, nilai intensitas komponen *red* (*red-channel*) lebih tinggi daripada nilai-nilai intensitas komponen *green* dan *blue* [8]. Sedangkan, untuk data *testing* hanya dilakukan *resize* dengan skala 0,25 dan konversi RGB ke *Red Channel*.

2.3. Transformasi Wavelet

Transformasi *wavelet* digunakan untuk memberikan kemudahan dalam kompresi, transmisi serta analisis citra. Dalam transformasi *wavelet*, citra dibagi empat himpunan berbeda dari *sub-band* citra yaitu LL1, LH1, HL1, HH1 [11]. Sebuah *wavelet* dapat diperoleh dengan mengiterasi sehimpunan *filter lowpass* (LL) dan *highpass* (HH). *Sub-band* LL1 (level tertinggi) dari koefisien *wavelet* merupakan sebuah aproksimasi atas citra asli pada resolusi rendah yang bergantung pada level *wavelet* [12].

Transformasi *wavelet* level pertama dari citra asli menghasilkan empat citra yaitu LL1, LH1, HL1, dan HH1 dengan masing-masing ukuran $\frac{1}{4}$ ($\frac{1}{2}$ kolom * $\frac{1}{2}$ baris) dari ukuran citra asli. Transformasi *wavelet* level kedua dilakukan proses yang sama dengan pada level pertama, akan tetapi citra input pada level kedua adalah citra LL1 hasil dari transformasi *wavelet* level 1. Selanjutnya, hasil dari proses transformasi *wavelet* level 2 juga menghasilkan empat citra yaitu LL2, LH2, HL2, HH2 masing-masing ukuran $\frac{1}{4}$ dari ukuran citra input LL1.

Indeks $j(j > 0, j \in \mathbb{Z})$ dimana $j = 0$ merupakan citra asli dan $j = J$ adalah level terkecil citra hasil proses transformasi *wavelet*.

Proses transformasi citra diawali dengan membagi citra menjadi block non-overlap 2×2 yang merupakan nilai intensitas piksel pada posisi baris m dan kolom n .

$$\begin{bmatrix} a & b \\ c & d \end{bmatrix}$$

Persamaan transformasi *wavelet Haar* bekerja secara *non-overlapping* menggunakan matriks berukuran 2×2 sebagai berikut :

$$LL = \frac{1}{2}(a + b + c + d) \quad (1)$$

$$LH = \frac{1}{2}(a + b - c - d) \quad (2)$$

$$HL = \frac{1}{2}(a - b + c - d) \quad (3)$$

$$HH = \frac{1}{2}(a - b - c + d) \quad (4)$$

Persamaan transformasi *wavelet* balik menggunakan persamaan sebagai berikut :

$$a = \frac{1}{2}(LL + LH + HL + HH) \quad (5)$$

$$b = \frac{1}{2}(LL + LH - HL - HH) \quad (6)$$

$$c = \frac{1}{2}(LL - LH + HL - HH) \quad (7)$$

$$d = \frac{1}{2}(LL - LH - HL + HH) \quad (8)$$

2.4. Ekstraksi GLCM

Dalam penelitian ini GLCM digunakan sebagai ekstraksi fitur tekstur, selanjutnya untuk melakukan perhitungan fitur-fitur pada GLCM adalah dengan cara membuat *matrix Co-Occurrence* terlebih dahulu, kemudian dilanjutkan dengan menentukan hubungan spasial antara piksel referensi dan piksel tetangga berdasarkan jarak $d = 1$ dan orientasi sudut θ dalam empat arah dengan interval sudut 45° , yaitu 0° , 45° , 90° , dan 135° . Fitur yang digunakan pada penelitian ini, meliputi *angular second moment* (ASM), *contrast*, *inverse different moment* (IDM), entropi, dan korelasi. Diagram blok ekstraksi fitur ditunjukkan pada gambar 2. Perhitungan fitur tekstur berdasarkan persamaan matematika yang dijelaskan pada [13] [14] [15] ditampilkan dalam rumus berikut.

$$ASM = \sum_{i=1}^L \sum_{j=1}^L (P(i, j))^2 \quad (9)$$

$$Contrast = \sum_{n=1}^L n^2 \{ \sum_{|i-j|=n} P(i, j) \} \quad (10)$$

$$IDM = \sum_{i=1}^L \sum_{j=1}^L \frac{(P(i, j))^2}{1 + (i - j)^2} \quad (11)$$

$$Entropi = - \sum_{i=1}^L \sum_{j=1}^L (P(i, j)) \log(P(i, j)) \quad (12)$$

$$Korelasi = \frac{\sum_{i=1}^L \sum_{j=1}^L (i - \mu_i')(i - \mu_j')(P(i, j))}{\sigma_i \sigma_j} \quad (13)$$


dengan

$$\mu_i' = \sum_{i=1}^L \sum_{j=1}^L i * P(i, j) \quad (14)$$

$$\mu_j' = \sum_{i=1}^L \sum_{j=1}^L j * P(i, j) \quad (15)$$

$$\sigma_i^2 = \sum_{i=1}^L \sum_{j=1}^L P(i, j)(i - \mu_i')^2 \quad (16)$$


$$\sigma_j^2 = \sum_{i=1}^L \sum_{j=1}^L P(i, j)(i - \mu_j')^2 \quad (17)$$



Gambar 2. Diagram Blok Ekstraksi Fitur

2.5. Klasifikasi

Klasifikasi batik tulis dilakukan dengan *Backpropagation Neural Network* (BPNN) dan *k-Nearest Neighbor* (k-NN) berdasar fitur tekstur. Metode Klasifikasi BPNN merupakan model *neural network* yang diakui secara kritis dengan kapasitas pemodelan non parametrik dan non liniernya, kemampuan beradaptasi yang kuat, serta kemampuan komputasi parallel [7]. Pada gambar 5 menunjukkan arsitektur dari metode klasifikasi BPNN disusun dengan 5 neuron *input* sesuai jumlah fitur tekstur yang dihasilkan GLCM dan 2 neuron *output*.



Gambar 3. Arsitektur BPNN

Metode klasifikasi k-NN merupakan metode klasifikasi berdasarkan data pembelajaran yang jaraknya paling dekat dengan objek [5] [16]. Dekat atau jauhnya objek dihitung berdasarkan *Euclidean Distance* yang direpresentasikan sebagai berikut :

$$d = \sqrt{(a_1 + b_1)^2 + (a_2 + b_2)^2 + \dots + (a_n + b_n)^2} \quad (18)$$

$$d = \sqrt{\sum_{i=1}^n (a_n + b_n)^2} \quad (19)$$

Dalam penelitian ini digunakan *k-fold cross validation* dimana $k=10$ pada data training dibagi secara random ke dalam 10 bagian dengan perbandingan yang sama [14]. Proses pembagian data training dan data testing mengikuti *fold cross validation*.

3. HASIL DAN PEMBAHASAN

3.1 Pengukuran Performansi

Dalam pengukuran performansi untuk memperkirakan nilai benar dan salah dibutuhkan sebuah algoritma yang mana dalam penelitian ini menggunakan *confusion matrix*. Pengukuran ini sering digunakan sebagai metode evaluasi untuk

memprediksi berdasarkan kelas dan matriks. Evaluasi tersebut bertujuan untuk menilai berapa persen kinerja dari sistem dapat mengenali data set citra batik tulis yang telah disediakan sewaktu proses pengklasifikasian. Dengan menggunakan *confusion matrix*, nilai akurasi dari proses klasifikasi dihitung dengan menggunakan persamaan (20). Pada tabel 2 terdapat 4 kondisi dalam *confusion matrix*.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (20)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (21)$$

$$\text{Recall} = \frac{TP}{TP+TN} \quad (22)$$

Tabel 2. *Confusion Matrix*

Predicted	Observed	
	Actual Positive	Actual Negative
Positive	TP	FN
Negative	FP	TN

Keterangan :

- TP (True Positive) : jumlah data dengan nilai sebenarnya positif dan nilai prediksi positif.
- TN (True Negative) : jumlah data dengan nilai sebenarnya negatif dan nilai prediksi negatif.
- FP (False Positive) : jumlah data dengan nilai sebenarnya negatif dan nilai prediksi positif.
- FN (False Negative) : jumlah data dengan nilai sebenarnya positif dan nilai prediksi negative.

3.2 Hasil Eksperimen

Penelitian ini menggunakan *Matlab* dan *Rapidminer* sebagai pengolah data untuk mendukung eksperimen ini. Semua tahapan *pre-processing* dan ekstraksi fitur tekstur dilakukan di *Matlab* dan sistem penilaian hasil klasifikasi dilakukan di *Rapidminer*. *Wavelet filter* yang digunakan adalah *Haar (db1)*, *Coiflet (coif2)* dan *biorthogonal (bior2.2 & bior5.5)*. Ekstraksi fitur tekstur dari GLCM berupa 5 fitur dengan interval sudut 45° sebagai variabel dalam proses klasifikasi yaitu *Angular Second Moment*, *Contrast*, *Inverse Different Moment*, *Entropy*, *Correlation*.

Klasifikasi BPNN dilakukan dengan parameter *training cycles* = 1000, *learning rate* = 0.3, dan *momentum* = 0.3. Sedangkan klasifikasi k-NN dilakukan dengan parameter nilai *k* sebesar 1, 3 dan 5. Nilai akurasi dari hasil eksperimen berdasarkan fitur tekstur akan dibandingkan dengan metode klasifikasi BPNN dan k-NN. Dari hasil eksperimen memperlihatkan perbedaan hasil pada setiap *wavelet filter* dan sudut θ , yang mana data citra batik diklasifikasikan dengan benar dan tidak.

Eksperimen pertama ditunjukkan pada tabel 3 yang menunjukkan hasil perbandingan nilai akurasi dari setiap *wavelet filter* dan fitur tekstur berdasarkan sudut θ dengan interval 45° dalam klasifikasi menggunakan metode BPNN. Dari tabel 3, performansi metode klasifikasi BPNN mendapatkan hasil maksimal dengan nilai akurasi sebesar 90,11%. Hasil akurasi tertinggi ditunjukkan dari proses klasifikasi menggunakan metode BPNN berdasarkan fitur tekstur dengan *wavelet filter bior2.2* pada sudut 45° .

Pada eksperimen kedua ditunjukkan pada tabel 4 yang menunjukkan hasil perbandingan nilai akurasi dari setiap *wavelet filter* dan fitur tekstur berdasarkan sudut θ dengan interval 45° dalam klasifikasi menggunakan metode k-NN dengan nilai $k=1$. Dari tabel 4, performansi metode klasifikasi k-NN mendapatkan hasil maksimal dengan nilai akurasi sebesar 96,00%. Hasil akurasi tertinggi ditunjukkan dari proses klasifikasi menggunakan metode k-NN berdasarkan fitur tekstur dengan *wavelet filter bior 2.2* pada sudut 45° dan nilai $k=1$.

Selanjutnya eksperimen ketiga ditunjukkan pada tabel 5 yang menunjukkan hasil perbandingan nilai akurasi dari setiap *wavelet filter* dan fitur tekstur berdasarkan sudut θ dengan interval 45° dalam klasifikasi menggunakan metode k-NN dengan nilai $k=3$. Dari tabel 5, performansi metode klasifikasi k-NN mendapatkan hasil maksimal dengan nilai akurasi sebesar 95,33%. Hasil akurasi tertinggi ditunjukkan dari proses klasifikasi menggunakan metode k-NN berdasarkan fitur tekstur dengan *wavelet filter haar* dan *coif 2* pada sudut 90° dan nilai $k=3$.

Kemudian eksperimen keempat ditunjukkan pada tabel 6 yang menunjukkan hasil perbandingan nilai akurasi dari setiap wavelet filter dan fitur tekstur berdasarkan sudut θ dengan interval 45° dalam klasifikasi menggunakan metode k-NN dengan nilai $k=5$. Dari tabel 6, performansi metode klasifikasi k-NN mendapatkan hasil maksimal dengan nilai akurasi sebesar 93,67%. Hasil akurasi tertinggi ditunjukkan dari proses klasifikasi menggunakan metode k-NN berdasarkan fitur tekstur dengan *wavelet filter bior 2.2* pada sudut 45° dan nilai $k=5$.

Tabel 3. Hasil Akurasi Klasifikasi BPNN

<i>Wavelet Filter</i>	Sudut θ	<i>Accuracy (%)</i>
<i>Haar</i>	0	84,89
	45	85,33
	90	78,22
	135	83,44
<i>Coif 2</i>	0	84,89
	45	85,78
	90	78,22
	135	83,44
<i>Bior 2.2</i>	0	86,11
	45	90,11
	90	83,33

	135	83,89
<i>Bior 5.5</i>	0	78,89
	45	72,78
	90	74,00
	135	72,56

Tabel 4. Hasil Akurasi Klasifikasi k-NN dengan Nilai $k=1$

<i>Wavelet Filter</i>	Sudut θ	<i>Accuracy (%)</i>
<i>Haar</i>	0	95,00
	45	95,22
	90	95,33
	135	94,11
<i>Coif 2</i>	0	95,00
	45	95,22
	90	95,33
	135	94,11
<i>Bior 2.2</i>	0	94,78
	45	96,00
	90	95,67
	135	94,33
<i>Bior 5.5</i>	0	94,78
	45	92,89
	90	94,56
	135	91,33

Tabel 5. Hasil Akurasi Klasifikasi k-NN dengan Nilai $k=3$


<i>Wavelet Filter</i>	Sudut θ	<i>Accuracy (%)</i>
<i>Haar</i>	0	93,89
	45	94,22
	90	95,33
	135	92,67
<i>Coif 2</i>	0	93,89
	45	94,22
	90	95,33
	135	92,67
<i>Bior 2.2</i>	0	91,89
	45	94,33
	90	93,67

	135	93,33
<i>Bior 5.5</i>	0	92,89
	45	91,11
	90	92,89
	135	89,67

Tabel 6. Hasil Akurasi Klasifikasi k-NN dengan Nilai $k=5$

<i>Wavelet Filter</i>	Sudut θ	<i>Accuracy (%)</i>
<i>Haar</i>	0	92,78
	45	93,67
	90	93,56
	135	91,56
<i>Coif 2</i>	0	92,78
	45	93,67
	90	93,56
	135	91,56
<i>Bior 2.2</i>	0	90,78
	45	93,00
	90	92,33
	135	92,89
<i>Bior 5.5</i>	0	92,33
	45	89,44
	90	92,22
	135	88,00

Dari eksperimen pertama hingga keempat telah dihasilkan beberapa nilai akurasi maksimal di setiap metode klasifikasi BPNN dan k-NN. Pada gambar 3 menunjukkan grafik perolehan nilai akurasi tertinggi dari setiap metode klasifikasi BPNN dan k-NN dengan nilai k sebesar 1, 3 dan 5.

**Gambar 4.** Grafik Akurasi Tertinggi dari Metode Klasifikasi

Tabel 7 menunjukkan confusion matrix hasil evaluasi dari metode klasifikasi k-NN berdasarkan fitur tekstur dengan *wavelet filter*. Hasil evaluasi menunjukkan bahwa akurasi tertinggi diperoleh metode klasifikasi k-NN berdasarkan fitur tekstur dengan *wavelet filter biorthogonal (bior2.2)* pada sudut 45° dengan nilai $k=1$.

Tabel 7. *Confusion Matrix* Metode k-NN $k=1$

<i>Accuracy</i>	96,00%		
<i>Predicted</i>	<i>Observed</i>		<i>Precision</i>
	Klasik	Kontemporer	
Klasik	433	19	95.80%
Kontemporer	17	431	96.21%
<i>Recall</i>	96.22%	95.78%	

4. KESIMPULAN

Dalam penelitian ini, dengan metode klasifikasi *k-Nearest Neighbor* (k-NN) dengan parameter $k = 1$ berdasarkan *wavelet filter biorthogonal (bior2.2)* pada sudut 45° fitur GLCM mampu menghasilkan nilai akurasi tertinggi yaitu sebesar 96,00% dibanding dengan lainnya.

Hasil rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif ditunjukkan dengan *recall* sebesar 96,22%, dan hasil rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif ditunjukkan dengan *precision* sebesar 96,21%.

Berdasarkan hasil penelitian ini, disarankan untuk diperluas lagi jenis data batik tulis yang mempunyai ciri khas masing-masing. Selain itu, melakukan uji coba dengan metode lainnya seperti halnya peningkatan kualitas citra dalam *pre-processing* atau pemilihan fitur yang lebih spesifik agar dapat meningkatkan akurasi lebih baik.

DAFTAR PUSTAKA

- [1] UNESCO, "Indonesia Batik," 2009. <http://www.unesco.org/culture/ich/en/RL/indonesian-batik-00170> (accessed Sep. 21, 2021).
- [2] Y. Sari, "Klasifikasi Pengenalan Motif Batik Berbasis Image Retrieval," *Jukung (Jurnal Tek. Lingkungan)*, vol. 4, no. 2, pp. 27–33, 2018, doi: 10.20527/jukung.v4i2.6581.
- [3] N. Luh and W. Sri, "Deteksi Batik Parang Menggunakan Fitur Co-Occurrence Matrix Dan Geometric Moment Invariant Dengan Klasifikasi KNN," *LONTAR Komput. VOL. 7, NO.1, April 2016*, vol. 7, no. 1, pp. 715–725, 2016.
- [4] K. A. N. Ignatia Dhian E.K.R, "Klasifikasi Batik Menggunakan KNN

- Berbasis Wavelet,” *Semin. Nas. Teknol. Inf. dan Komun. 2016 (SENTIKA 2016)*, vol. Yogyakarta, no. ISSN : 2089-9815, pp. 615–623, 2016.
- [5] T. Y. Prahudaya and A. Harjoko, “Metode Klasifikasi Mutu Jambu Biji Menggunakan Knn Berdasarkan Fitur Warna Dan Tekstur,” *J. Teknosains*, vol. 6, no. 2, p. 113, 2017, doi: 10.22146/teknosains.26972.
 - [6] A. E. Minarno, A. S. Maulani, A. Kurniawardhani, F. Bimantoro, and N. Suciati, “Comparison of methods for Batik classification using multi texton histogram,” *Telkomnika (Telecommunication Comput. Electron. Control)*, vol. 16, no. 3, pp. 1358–1366, 2018, doi: 10.12928/TELKOMNIKA.v16i3.7376.
 - [7] A. F. Achmalia, Walid, and Sugiman, “Peramalan Penjualan Semen Menggunakan Backpropagation,” *UNNES J. Math.*, vol. 8, no. 1, pp. 92–106, 2019.
 - [8] B. Zaman and M. B. Hanif, “EKSTRAKSI FITUR BERBASIS WAVELET FILTER UNTUK MENINGKATKAN KINERJA NEURAL NETWORK PADA CITRA BATIK TULIS,” *E-PROSIDING Semin. Nas. Has. Penelit. Lemb. Penelit. DAN Pengabd. Kpd. Masy. Univ. SEMARANG*, pp. 374–380, 2021.
 - [9] I. Nurhaida, H. Wei, R. A. M. Zen, R. Manurung, and A. M. Arymurthy, “Texture fusion for batik motif retrieval system,” *Int. J. Electr. Comput. Eng.*, vol. 6, no. 6, pp. 3174–3187, 2016, doi: 10.11591/ijece.v6i6.12049.
 - [10] Y. Brasilka and D. Andreswari, “Klasifikasi Citra Batik Besurek Menggunakan Jaringan Syaraf Tiruan Self Organizing Map (Som),” vol. 3, no. 2, pp. 132–145, 2015.
 - [11] A. E. Minarno, Y. Munarko, A. Kurniawardhani, F. Bimantoro, and N. Suciati, “Texture Feature Extraction Using Co-Occurrence Matrices of Sub-Band Image For Batik Image Classification,” *2nd Int. Conf. Inf. Commun. Technol. Texture*, pp. 249–254, 2014.
 - [12] Rangkuti, “Content Based Batik Image Classification using Wavelet Transform and Fuzzy Neural Network,” *J. Comput. Sci.*, vol. 10, no. 4, pp. 604–613, Apr. 2014, doi: 10.3844/jcssp.2014.604.613.
 - [13] A. Kadir and A. Susanto, *Pengolahan Citra*. Yogyakarta, 2012.
 - [14] R. A. Pramunendar, C. Supriyanto, Dwi Hermawan Novianto, Ignatius Ngesti Yuwono, G. F. Shidik, and P. N. Andono, “A classification method of coconut wood quality based on Gray Level Co-occurrence matrices,” in *2013 International Conference on Robotics, Biomimetics, Intelligent Computational Systems*, Nov. 2013, no. November, pp. 254–257, doi: 10.1109/ROBIONETICS.2013.6743614.
 - [15] C. S. K. Aditya, M. Hani’Ah, R. R. Bintana, and N. Suciati, “Batik classification using neural network with gray level co-occurrence matrix and statistical color feature extraction,” *Proc. 2015 Int. Conf. Inf. Commun. Technol. Syst. ICTS 2015*, pp. 163–167, 2016, doi: 10.1109/ICTS.2015.7379892.
 - [16] A. E. Minarno, Y. Azhar, F. D. Setiawan Sumadi, and Y. Munarko, “A Robust Batik Image Classification using Multi Texton Co-Occurrence

Descriptor and Support Vector Machine,” *2020 3rd Int. Conf. Intell. Auton. Syst. ICoIAS 2020*, pp. 51–55, 2020, doi: 10.1109/ICoIAS49312.2020.9081833.