

OPTIMASI KLASIFIKASI BATIK BETAWI MENGGUNAKAN DATA AUGMENTASI DENGAN METODE KNN DAN GLCM

Dadang Iskandar Mulyana¹, Ali Akbar²

¹Teknik Informatika, Sekolah Tinggi Ilmu Komputer Cipta Karya Informatika

²Teknik Informatika, Sekolah Tinggi Ilmu Komputer Cipta Karya Informatika

Jl. Radin Inten II No. 8 Duren Sawit Jakarta Timur Indonesia

¹mahvin2012@gmail.com, ²aliakbar04dev@gmail.com

ABSTRAK

Batik telah menjadi salah satu warisan budaya leluhur negara Indonesia yang terus dikembangkan, dilestarikan dan dijadikan identitas budaya bangsa Indonesia. Salah satu batik yang belum terangkat ke permukaan adalah batik Betawi. Penelitian ini dilakukan untuk mengklasifikasikan batik betawi ke dalam beberapa kelas berdasarkan motif nya sehingga mempermudah dalam pengenalan batik betawi secara citra digital. Metode yang digunakan adalah *K-Nearest Neighbor* untuk menentukan kedekatan antara citra uji dengan citra latih sedangkan *Gray-Level Co-occurrence Matrix* untuk ekstraksi ciri teksturnya. Untuk dataset penulis menggunakan dataset publik dari website *Kaggle* yang berjudul "*Indonesian Batik Motifs*" dan beberapa sumber dari *Google*. Karena kekurangan banyak dataset, maka penulis mengaugmentasi dataset yang sudah di dapatkan hingga berjumlah 1.020 citra. Dan hasilnya persentase nilai akurasi tertinggi terdapat pada motif Burung Hong, Monas, Nusa Kelapa, Pengantin Betawi, Ondel-Ondel, Rasamala dan Salakanagara sebanyak 97%. Untuk nilai akurasi terendah terdapat pada motif Kali Ciliwung dan Topeng Betawi sebanyak 93%. Selebihnya yaitu motif Golok, Penari Ngarojeng dan Pucuk Rebung mendapatkan nilai akurasi sebanyak 95%. Dan nilai rata-rata akurasi dari semua motif batik Betawi ini mendapatkan nilai 96%. Hasil ini menunjukkan bahwa penelitian ini sangat baik.

Kata kunci : Klasifikasi, Batik Betawi, *K-Nearest Neighbor*, *Gray-Level Co-occurrence Matrix*.

ABSTRACT

Batik has become one of the ancestral cultural heritage of the Indonesian state which continues to be developed, preserved and used as the cultural identity of the Indonesian nation. One of the batik that has not been raised to the surface is Betawi batik. This research was conducted to classify Betawi batik into several classes based on the motifs so as to facilitate the introduction of Betawi batik in digital images. The method used is *K-Nearest Neighbor* to determine the proximity between the test image and the training image, while the *Gray-Level Co-occurrence Matrix* is used to extract the texture features. For the dataset the author uses a public dataset from the *Kaggle* website entitled "*Indonesian Batik Motifs*" and several sources from *Google*. Due to the lack of many datasets, the authors augment the datasets that have been obtained to a total of 1,020 images. And the result is that the highest percentage of accuracy values is found in the motifs of the Hong Bird, Monas, Nusa Kelapa, Betawi Brides, Ondel-Ondel, Rasamala and Salakanagara as much as 97%. The lowest accuracy value is found in the Kali Ciliwung motif and the Betawi Mask as much as 93%. The rest, namely the motif of Golok, Ngarojeng dancers and Pucuk Rebung get an accuracy value of 95%. And the average value of accuracy of all these Betawi batik motifs gets a value of 96%. These results indicate that this research is very good.

Keywords : Classification, Batik Betawi, *K-Nearest Neighbor*, *Gray-Level Co-occurrence Matrix*.

1. PENDAHULUAN

Batik adalah seni melukis di atas kain untuk membuat pakaian yang telah menjadi salah satu ciri budaya keluarga kerajaan Indonesia kuno. Ada berbagai jenis batik di Indonesia, tergantung dari daerah asal atau ciri-ciri warnanya. Menurut [1] Batik adalah kain bermotif yang dibuat khusus dengan cara menulis atau waxing kain tersebut kemudian diolah dengan cara tertentu yang memiliki ciri khas tersendiri. Setiap motif batik juga memiliki cerita tersendiri. Batik itu sendiri telah menjadi salah satu warisan budaya leluhur negara Indonesia yang terus dikembangkan, dilestarikan dan dijadikan identitas budaya bangsa Indonesia [2]. Batik menjadi identitas sekaligus simbol masyarakat baik lokal maupun nasional. Batik merupakan salah satu dari kecerdasan lokal yang dapat diidentifikasi melalui coraknya. Kita dapat menentukan batik daerah mana yang diproduksi melalui corak batik tersebut. Pada taraf nasional, batik dianggap mewakili identitas budaya masyarakat Indonesia. Kain batik Indonesia sendiri telah ditetapkan sebagai warisan budaya dunia oleh UNESCO pada 2 Oktober 2009 yang berdampak positif bagi pertumbuhan dan perkembangan ekonomi masyarakat Indonesia [3]. Seiring dengan semakin populernya batik, berbagai daerah berusaha mengembangkan batik dengan meningkatkan tradisi dan ciri khas daerah tersebut. Salah satunya yaitu DKI Jakarta yang mengusung Batik Betawi. Bagian dari khasanah kerajinan Indonesia, kain batik lebih dari sekadar pakaian. Hiasan batik tersebut merupakan representasi dari bentuk yang dapat memberikan wawasan dan refleksi terhadap budaya sang pencipta, dalam hal ini masyarakat Betawi.

Seiring waktu, banyak motif batik Betawi bermunculan bersama dengan motif batik Tumpal yang memiliki bentuk segitiga siku-siku di bagian depan. Adapula gambar burung hong yang melambangkan kebahagiaan yang merupakan salah satu ciri khas batik Betawi karena merupakan hasil identifikasi dengan batik Hokokai. Perkembangan batik Betawi sudah ada sejak zaman Batavia. Keanekaragaman ornamen batik merupakan ekspresi dari bentuk yang dapat memberikan wawasan dan refleksi terhadap budaya pembuatnya, dalam hal ini masyarakat Betawi [4]. Dahulu batik Betawi dapat ditemukan di beberapa tempat di wilayah Jakarta seperti Palmerah, Bundungan Hilir, Karet Tengsin dan Kebon Kacang. Beberapa contoh batik asli Betawi dapat ditemukan di Museum Tekstil di kawasan Tanah Abang Jakarta Pusat [5]. Dan dari segi warna, pada umumnya Batik Betawi menggunakan warna-warna cerah untuk menciptakan kesan dinamis, ceria dan optimis. Komposisi warna merah, kuning, jingga, ungu, hijau, dan biru sering diterapkan secara harmonis pada ornamen, huruf, dan latar belakang. Warna-warna cerah tersebut diambil dari karakter batik Betawi modern yang populer dengan visualisasi objek-objek populer betawi [6]. Menurut Pratiwi (Kusumawardhani, 2017), warna cerah batik Betawi diperoleh dari warna alam.

Beragamnya motif yang dimiliki batik Betawi menyebabkan kesulitan dalam mengenali motif-motifnya dari segi citra digital. Selain itu ada masalah lain yang tak kalah penting yaitu terbatasnya jumlah citra dataset di internet mengingat jenis batik Betawi tidak sepopuler batik Pekalongan, Cirebon, Solo dan sebagainya. Dengan adanya masalah ini memunculkan ide kepada penulis untuk melakukan penelitian tentang mengklasifikasikan citra batik Betawi berdasarkan kelas masing-masing sehingga dapat dengan mudah dikenali berdasarkan motif batiknya. Untuk mengatasi keterbatasan citra dataset, penulis mengaugmentasi dataset batik Betawi tersebut sehingga diharapkan mendapatkan hasil yang maksimal dari penelitian ini. Ada 12 kelas atau motif batik Betawi yang penulis gunakan dalam penelitian ini yaitu motif Burung Hong, Kali Ciliwung, Monas, Nusa Kelapa, Ondel-Ondel, Penari Ngarojeng, Pengantin Betawi, Pucuk Rebung, Rasamala, Golok, Salakanagara Dan Topeng Betawi yang ditotal berjumlah 1.020 citra. Setelah di Augmentasi kemudian di ekstraksi fitur menggunakan *Gray Level Co-Occurrence Matrix (GLCM)*. Sementara metode yang penulis pilih adalah *K-Nearest Neighbor (KNN)*.

2. METODOLOGI PENELITIAN

2.1 Klasifikasi

Di dalam KBBI, klasifikasi adalah penyusunan bersistem dalam kelompok atau golongan menurut kaidah atau standar yang ditetapkan. Secara harfiah bisa pula dikatakan bahwa klasifikasi adalah pembagian sesuatu menurut kelas-kelas. Sedangkan menurut [7] Klasifikasi atau *Clustering* adalah teknik penambangan data tanpa pengawasan yang mempartisi titik data yang tidak berlabel ke dalam kelompok yang berbeda berdasarkan kesamaannya. Selama tiga dekade terakhir, banyak algoritma pengelompokan telah diusulkan, dan algoritma ini telah mencapai hasil yang signifikan dalam aplikasi di beberapa domain. Seringkali bermanfaat atau perlu untuk memeriksa seberapa baik hasil klasifikasi untuk kelas-kelas tertentu [8].

Menurut [9] Selama satu dekade terakhir, sejumlah besar pengklasifikasi piksel diterapkan, termasuk *Random Forest*, *KNN*, *SVM* dan *Sparse Representation*. Namun, metode ini hanya berfokus pada informasi

spektral, mengabaikan informasi kontekstual spasial yang juga mempengaruhi kinerja klasifikasi. Bagaimanapun, itu adalah fenomena universal bahwa gambar penginderaan jauh ada "tubuh yang berbeda dengan spektrum yang sama" atau "tubuh yang sama dengan spektrum yang berbeda".

Klasifikasi citra telah mendapat perhatian besar dari komunitas ilmiah, misalnya banyak literatur terkait *Pascal VOC* dan ImageNet. Sebagian besar pendekatan modern mengikuti pendekatan *Bag-Ofword (BOW)*, diwakili oleh pipa 3 langkah: ekstraksi fitur gambar lokal, penyandian deskriptor citra lokal dan penyatuan deskriptor yang disandikan ini ke dalam representasi citra global, pelatihan dan klasifikasi deskriptor citra global untuk tujuan pengenalan objek [10].


Sementara itu menurut [11] Hasil dari proses klasifikasi seringkali mengalami masalah yaitu ketidaktepatan dalam klasifikasi. Untuk mengatasi masalah tersebut maka algoritma klasifikasi perlu ditingkatkan optimasinya.

2.2 Data Augmentasi

Data hadir dalam jumlah besar, tetapi masalah kumpulan data yang tidak seimbang muncul berulang kali, mengganggu pengklasifikasi dan mengurangi akurasi [12]. Augmentasi data adalah proses memodifikasi atau memanipulasi suatu citra sehingga citra asli dalam bentuk yang telah disiapkan berubah bentuk dan posisinya. Augmentasi data bertujuan untuk memungkinkan mesin belajar dan mengenali dari gambar yang berbeda, dan dapat digunakan untuk merekonstruksi data. Dalam kebanyakan kasus, penggunaan peningkatan data berhasil meningkatkan kinerja model. Peningkatan ini terjadi karena mesin dapat mengenali lebih banyak objek dengan bentuk dan pola yang berbeda. Peningkatan data ini penting mengingat banyaknya keuntungan yang bisa diperoleh seperti yang telah dijelaskan sebelumnya. Selain itu, dalam menambah data *deep learning* juga akan membantu mengatasi banyak masalah umum dalam deep learning yaitu data hungry (banyak data yang dibutuhkan) karena setiap level data akan mendapatkan data baru dari increment yang dilakukan. Lebih banyak data baru dapat diperoleh jika kita menggabungkan beberapa jenis augmentasi data. Oleh karena itu, sebuah gambar dapat memiliki beberapa peningkatan [13].

2.3 Gray Level Co-Occurrence Matrix (GLCM)

Gray-Level co-occurrence matrix (GLCM) adalah metode pengenalan pola yang awalnya digunakan sebagai fungsi ekstraksi citra yang pertama kali diusulkan oleh *Haralick et.al.* *GLCM* adalah matriks di mana jumlah baris dan kolom sama dengan jumlah tingkat keabuan dalam sebuah gambar [14]. Sedangkan menurut [15] *GLCM* dapat diperoleh dari citra keabuan, dan karakteristiknya dapat digunakan untuk merepresentasikan beberapa fitur tekstur citra. Momen perbedaan terbalik mewakili homogenitas lokal dari suatu gambar. Momen perbedaan terbalik yang besar menunjukkan bahwa wilayah tekstur citra hanya berbeda sedikit dan homogenitas lokal sangat seragam. *GLCM* mewakili hubungan antara 2 piksel ketetanggaan dengan intensitas, jarak dan sudut dalam skala abu-abu. Ada 4 sudut yang bisa digunakan dalam *GLCM*, antara lain 0° , 45° , 90° , 135° [16].



Gambar 1. Orientasi Sudut Dan Jarak Pada Metode GLCM

Sumber : <https://images.app.goo.gl/qVWBXU1icNhNNUCJ6>

2.4 K-Nearest Neighbor (KNN)

Menurut [17] K-Nearest Neighbor adalah pendekatan non-parametrik, yang mengklasifikasikan titik data tertentu menurut mayoritas tetangganya. Algoritma KNN menyelesaikan eksekusinya dalam dua langkah, pertama menemukan jumlah tetangga terdekat dan kedua mengklasifikasikan titik data ke dalam kelas tertentu menggunakan langkah awal tadi. Dan menurut [18] Algoritma K-Nearest Neighbor (K-NN) adalah sebuah metode klasifikasi terhadap sekumpulan data berdasarkan pembelajaran data yang sudah

terklasifikasikan sebelumnya. Sedangkan menurut [19] K-Nearest Neighbor (KNN) adalah metode yang menggunakan algoritma supervised mana hasil dari instance kueri baru diurutkan berdasarkan mayoritas kategori di KNN. Algoritma KNN menggunakan pembelajaran terawasi untuk menemukan pola baru dalam data dengan menghubungkan pola data yang ada dengan data baru. KNN merupakan metode klasifikasi untuk suatu dataset berdasarkan data latih yang telah diklasifikasikan menjadi objek baru berdasarkan atribut dan sampel latih. Metode ini bekerja secara sederhana, menggunakan jarak terpendek antara instance kueri dan sampel pelatihan untuk menentukan KNN-nya. Sampel pelatihan itu sendiri diproyeksikan ke dalam ruang dimensi untuk mewakili karakteristik data. Dan kekurangannya yaitu, biaya yang digunakan cukup besar karena, pada keseluruhan data dibutuhkan perhitungan Query Instance untuk perhitungan jaraknya [20]. Menurut [21] Pengujian klasifikasi menggunakan metode KNN (K-Nearest Neighbor) menggunakan data cluster dan fitur yang telah diekstraksi, jarak yang digunakan dalam metode ini menggunakan jarak Euclidean. Secara umum, rumus jarak Euclidean dalam ruang satu dimensi adalah sebagai berikut:

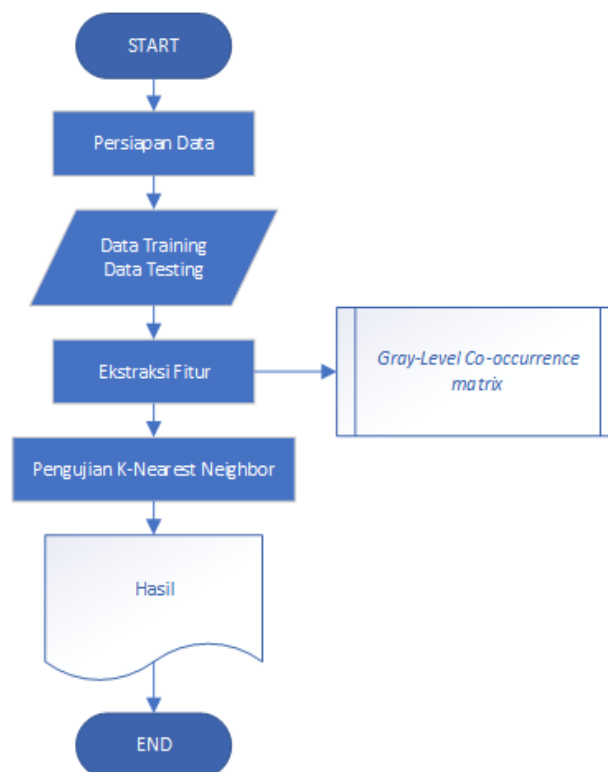
$$dis(x_1, x_2) = \sqrt{\sum_{i=0}^n (x_{1i} - x_{2i})^2}$$

Gambar 2. Formula jarak Euclidean satu variabel

Sumber : <https://ilmudatapy.com/algoritma-k-nearest-neighbor-knn-untuk-klasifikasi/>

2.5 Penerapan Metodologi

Berikut adalah tahapan metodologi yang digunakan dalam penelitian ini:

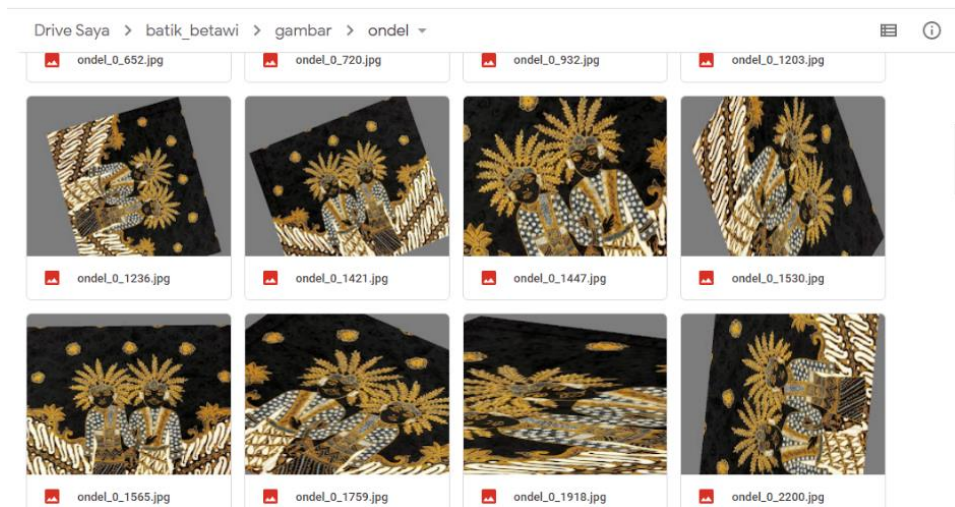


Gambar 3. Tahapan Metodologi Yang Penulis Gunakan

Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

2.5.1 Persiapan Data

Pada tahap awal yaitu persiapan data disini diartikan mengumpulkan citra dataset Batik Betawi yang sudah penulis kumpulkan setelah proses Augmentasi yang berjumlah 1.020 citra.




Gambar 4. Dataset motif ondel-ondel
Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

2.5.2 Data *Training* dan Data *Testing*

Pada tahap ini penulis memisahkan data *Training* dan Data *Testing*. Data *Training* yang penulis gunakan sebanyak 1.020 citra. Sedangkan data *Testing* yang penulis pakai berjumlah 300 citra.

2.5.3 Ekstraksi Fitur Dengan *Gray-Level Co-occurrence matrix (GLCM)*

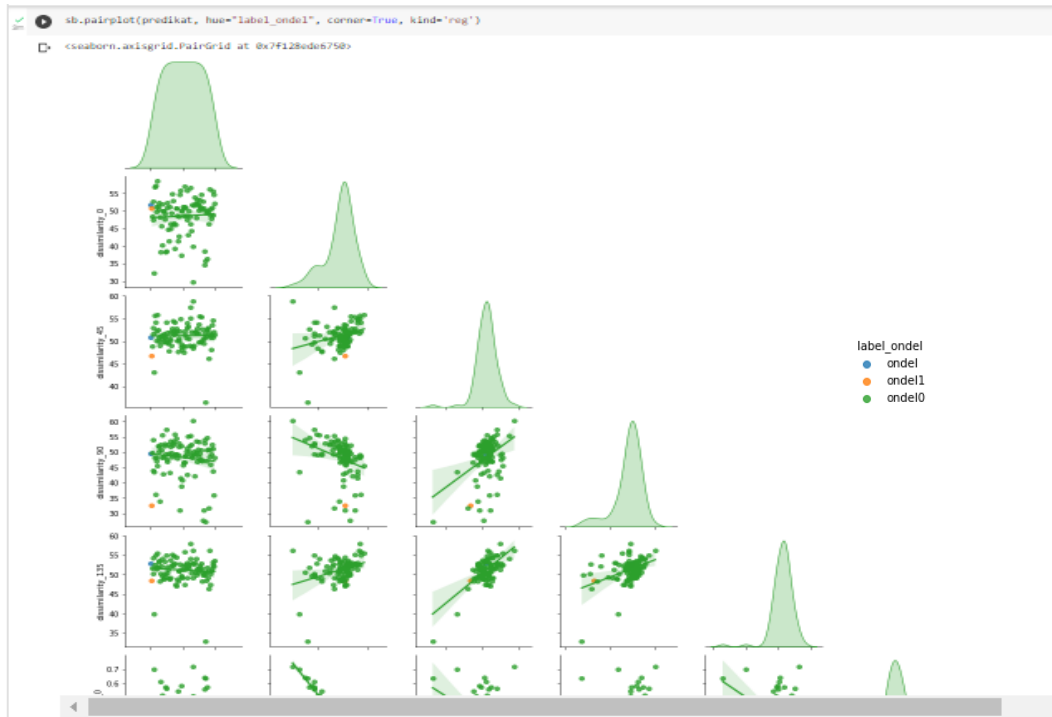
Pada tahap ini untuk mendapatkan ekstraksi fitur dari citra dengan menggunakan *GLCM*, adapun alasan menggunakan *GLCM* karena *GLCM* lebih mudah diimplementasikan untuk analisis tekstur dan batik sangat mudah dibedakan berdasarkan tekstur citranya.



Gambar 5. Dataset motif ondel-ondel yang telah di ekstraksi dengan *GLCM*
Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

2.5.4 Pengujian *K-Nearest Neighbor (KNN)*

Selanjutnya masuk ke tahap pengujian klasifikasi menggunakan metode *K-Nearest Neighbor* dengan data yang telah di kelompokkan dan telah diekstraksi cirinya, jarak yang digunakan pada metode ini adalah dengan perhitungan jarak ketetanggaan menggunakan pendekatan Euclidian Distance dengan persamaan [22].



Gambar 6. Visualisasi grafik penyebaran hasil ekstraksi GLCM motif ondel-ondel
 Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

3. HASIL DAN PEMBAHASAN

Pada penelitian ini, penulis menggunakan beberapa dataset publik website *Kaggle* yang berjudul “*Indonesian Batik Motifs*” dan beberapa sumber di *Google*. Dataset berjumlah 1.020 citra yang terdiri dari 12 motif terdiri dari motif burung hong, kali ciliwung, monas, nusa kelapa, ondel-ondel, penari ngarojeng, pengantin betawi, pucuk rebung, rasamala, golok, salakanagara dan topeng betawi. Kemudian memisahkan antara data *Training* sebanyak 70% dan data *Testing* sebanyak 30%.

Selanjutnya proses ekstraksi fitur untuk memperoleh informasi dari sebuah citra dimana hasil tersebut akan digunakan sebagai parameter proses prediksi menggunakan *KNN* nantinya. Dari penelitian yang dilakukan kali ini untuk mengambil citra menggunakan *GLCM*, alasan menggunakan *GLCM* adalah karena *GLCM* lebih mudah dilakukan untuk analisis tekstur dan batik mudah dibedakan dengan tekstur gambarnya. Yang terakhir adalah hasil ekstraksi *GLCM* akan ditempatkan pada variabel matriks berukuran $1 \times n$ dimana nilai n adalah *dissimilarity*, *correlation*, *homogeneity*, *contrast*, *ASM* dan *energy*. Pengujian ini menggunakan parameter sudut GLCM (0° , 45° , 90° , 135°) digunakan secara bersamaan dan jarak (d) sebesar 5 piksel.

```
[56] predikat = pd.read_csv("drive/MyDrive/csv_batik_betawi/ondel.csv")
predikat
```

Unnamed: 0	dissimilarity_0	dissimilarity_45	dissimilarity_90	dissimilarity_135	correlation_0	correlation_45	correlation_90	correlation_135	homogeneity_0	...	contrast_135
0	0	51.755569	50.905234	49.683333	52.954141	0.279328	0.308180	0.339745	0.267342	0.028409	4599.723958
1	1	50.831824	46.828887	32.574074	48.482724	0.371319	0.440001	0.665670	0.410475	0.046827	4427.384905
2	2	48.403917	48.847053	49.874691	51.606580	0.274198	0.256535	0.229987	0.186431	0.028170	4356.389101
3	3	52.674051	51.638211	44.096543	50.226626	0.272688	0.301249	0.476895	0.331243	0.032059	4374.002287
4	4	47.538433	52.970783	54.065926	54.343115	0.329587	0.214984	0.186068	0.179134	0.035390	4757.195245
...
95	95	47.888862	48.184959	49.458272	51.012576	0.368518	0.363761	0.345073	0.308582	0.041351	4485.112170
96	96	50.937087	53.545351	52.523457	51.483613	0.262267	0.188206	0.235501	0.249609	0.027700	4368.739964
97	97	55.711138	54.581301	43.816667	52.582698	0.206496	0.224392	0.461411	0.243620	0.029547	4763.445503
98	98	48.812729	50.839177	51.207037	53.262576	0.308421	0.257279	0.248078	0.200342	0.032213	4656.836255
99	99	52.111016	51.445376	48.312346	53.559959	0.202981	0.232549	0.318592	0.177413	0.029356	4704.617378

100 rows x 26 columns

```
[15] predikat = pd.read_csv("drive/MyDrive/csv_batik_betawi/ondel1.csv")
predikat
```

ion_0	correlation_45	correlation_90	correlation_135	homogeneity_0	...	contrast_135	ASM_0	ASM_45	ASM_90	ASM_135	energy_0	energy_45	energy_90	energy_135	label_ondel
79328	0.308180	0.339745	0.267342	0.028409	...	4599.723958	0.000103	0.000106	0.000107	0.000102	0.010147	0.010318	0.010347	0.010077	ondel0
71319	0.440001	0.665670	0.410475	0.046827	...	4427.384909	0.000179	0.000204	0.000351	0.000200	0.013379	0.014280	0.018731	0.014149	ondel1
74198	0.256535	0.229987	0.186431	0.028170	...	4356.389101	0.000104	0.000104	0.000100	0.000102	0.010219	0.010219	0.010020	0.010106	ondel0
72688	0.301249	0.476895	0.331243	0.032059	...	4374.002287	0.000105	0.000112	0.000138	0.000116	0.010270	0.010595	0.011751	0.010760	ondel0
79587	0.214984	0.186068	0.179134	0.035390	...	4757.195249	0.000107	0.000100	0.000097	0.000098	0.010344	0.009992	0.009870	0.009891	ondel0
...
32267	0.188206	0.235501	0.249609	0.027700	...	4368.739964	0.000099	0.000102	0.000102	0.000101	0.009953	0.010121	0.010094	0.010054	ondel0
76496	0.224392	0.461411	0.243620	0.029547	...	4763.445503	0.000112	0.000113	0.000130	0.000133	0.010600	0.010623	0.011405	0.011552	ondel0
78421	0.257279	0.248078	0.200342	0.032213	...	4656.836255	0.000103	0.000101	0.000102	0.000100	0.010147	0.010071	0.010079	0.010011	ondel0
12106	0.284241	0.610501	0.274680	0.023311	...	4439.732724	0.000097	0.000102	0.000134	0.000101	0.009832	0.010086	0.011584	0.010072	ondel0
12981	0.232549	0.318592	0.177413	0.029356	...	4704.617378	0.000102	0.000104	0.000111	0.000104	0.010114	0.010217	0.010542	0.010184	ondel0


Gambar 7. Hasil proses ekstraksi *GLCM* pada salah satu dataset yaitu motif ondel-ondel
 Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

Dari hasil proses ekstraksi fitur dengan *GLCM* diatas yang di ambil dari beberapa sudut mendapatkan nilai *dissimilarity 0°*, *dissimilarity 45°*, *dissimilarity 90°*, *dissimilarity 135°*, *correlation 0°*, *correlation 45°*, *correlation 90°*, *correlation 135°*, *homogeneity 0°*, *homogeneity 45°*, *homogeneity 90°*, *homogeneity 135°*, *contrast 0°*, *contrast 45°*, *contrast 90°*, *contrast 135°*, *ASM 0°*, *ASM 45°*, *ASM 90°*, *ASM 135°*, *energy 0°*, *energy 45°*, *energy 90°*, *energy 135°* yang nantinya akan digunakan untuk perhitungan akurasi klasifikasi dengan *K-Nearest Neighbor*.

```
print(classification_report(y_test, y_pred))
sb.heatmap(confusion_matrix(y_test, y_pred), annot=True)
```

	precision	recall	f1-score	support
ondel0	0.97	1.00	0.98	29
ondel1	0.00	0.00	0.00	1
accuracy			0.97	30
macro avg	0.48	0.50	0.49	30
weighted avg	0.93	0.97	0.95	30

Gambar 8. Hasil *Classification Report* salah satu motif batik yaitu ondel-ondel
 Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data



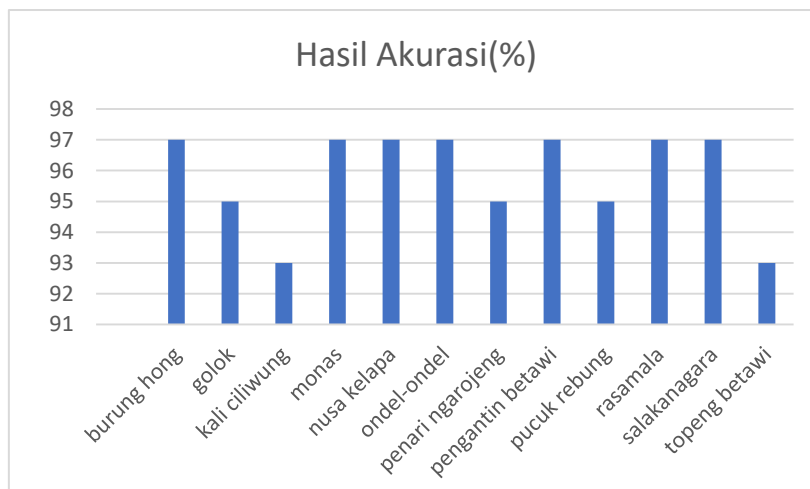
Gambar 9. Hasil *Confusion Matrix* salah satu motif batik yaitu ondel-ondel
 Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

Setelah mendapatkan nilai fitur, langkah selanjutnya adalah menentukan kelas motif batik berdasarkan kedekatannya dengan data latih dan data uji. Perhitungan jarak nilai ketetanggaan menggunakan pendekatan jarak *Euclidean*. Masuk ke tahap terakhir yaitu pengujian klasifikasi menggunakan metode *K-Nearest Neighbor* dengan data yang telah di ekstraksi diatas serta beberapa motif lain yang telah di uji maka di dapatkan hasil sebagai berikut :

Kelas/Motif Batik Betawi	Hasil Akurasi(%)
Burung Hong	97
Golok	95
Kali Ciliwung	93
Monas	97
Nusa Kelapa	97
Ondel-Ondel	97
Penari Ngarojeng	95
Pengantin Betawi	97
Pucuk Rebung	95
Rasamala	97
Salakanagara	97
Topeng Betawi	93
Rata-Rata Akurasi	96

Tabel 1. Hasil akurasi proses *K-Nearest Neighbor* pada dataset batik Betawi
 Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

Hasil akurasi dari tabel diatas mendapatkan nilai dengan akurasi tertinggi pada motif Burung Hong, Monas, Nusa Kelapa, Pengantin Betawi, Ondel-Ondel, Rasamala dan Salakanagara sebanyak 97%, sedangkan dengan nilai akurasi terendah terdapat pada motif Kali Ciliwung dan Topeng Betawi sebanyak 93%, selebihnya yaitu motif Golok, Penari Ngarojeng dan Pucuk Rebung mendapatkan nilai akurasi sebanyak 95%. Dan nilai rata-rata akurasi dari semua motif batik Betawi ini mendapatkan nilai 96%. Untuk lebih mudahnya jika dibuatkan diagram akurasi maka hasilnya akan seperti gambar dibawah ini :



Gambar 10. Hasil akurasi proses *K-Nearest Neighbor* dalam bentuk diagram
 Sumber : Gambar Olahan Data Sendiri dari Pengolahan Data

4. KESIMPULAN

Berdasarkan pemaparan diatas dapat disimpulkan bahwa *K-Nearest Neighbor (KNN)* mampu mengklasifikasikan citra batik Betawi yang telah di augmentasi kemudian di ekstraksi menggunakan fitur *Gray Level Cooccurrence Matrix (GLCM)* di dapatkan hasil 6 fitur yaitu *dissimilarity, correlation, homogeneity, contrast, ASM* dan *energy* dengan sudut 0° , 45° , 90° dan 135° dan Persentase nilai akurasi tertinggi terdapat pada motif Burung Hong, Monas, Nusa Kelapa, Pengantin Betawi, Ondel-Ondel, Rasamala dan Salakanagara sebanyak 97%. Untuk nilai akurasi terendah terdapat pada motif Kali Ciliwung dan Topeng Betawi sebanyak 93%. Selebihnya yaitu motif Golok, Penari Ngarojeng dan Pucuk Rebung mendapatkan nilai akurasi sebanyak 95%. Dan nilai rata-rata akurasi dari semua motif batik Betawi ini mendapatkan nilai 96%. Hasil ini menunjukkan bahwa penelitian ini sangat baik.

DAFTAR PUSTAKA

- [1] D. Hardiyanto, S. Kristiyana, D. Kurniawan, and D. A. Sartika, "Klasifikasi Motif Citra Batik Yogyakarta Menggunakan Metode Adaptive Neuro Fuzzy Inference System," *Setrum Sist. Kendali-Tenaga-elektronika-telekomunikasi-komputer*, vol. 8, no. 2, p. 229, 2019, doi: 10.36055/setrum.v8i2.6545.
- [2] E. Sentosa, D. I. Mulyana, A. F. Cahyana, and N. G. Pramuditasari, "Implementasi Image Classification Pada Batik Motif Bali Dengan Data Augmentation dan Convolutional Neural Network," *J. Pendidik. Tambusai*, vol. 6, no. 1, pp. 1451–1463, 2022.
- [3] D. C. Afreandhanie, "Kajian Motif Ondel-Ondel pada Batik Betawi," *Ornamen J. Kriya Seni*, vol. 15, no. 2, pp. 93–108, 2018, [Online]. Available: <https://jurnal.isi-ska.ac.id/index.php/ornamen/article/view/2538/2315>.
- [4] M. R. Srihardi, D. Pratama, and A. F. Muntazori, "KAJIAN MOTIF BATIK BETAWI SERACI KHAS BEKASI Pendahuluan," vol. 9, no. 1, pp. 47–63, 2021.
- [5] P. Kusumowardhani, "Identifikasi Unsur Visual Bentuk dan Warna yang Menjadi Ciri Khas Motif Ragam Hias Batik Betawi Tarogong Jakarta," *Semin. Nas. Seni dan Desain 2017*, pp. 97–105, 2017.
- [6] A. Priyono Susilo Ahmad, R. Kartika, and H. B. Wibowo, "Motif Batik Betawi Sebagai Inspirasi Dalam Desain Poster Peribahasa Indonesia," *Titik Imaji*, vol. 2, no. 1, pp. 11–18, 2019, doi: 10.30813/v2i1.1524.
- [7] J. H. Kim, J. H. Choi, Y. H. Park, C. K. S. Leung, and A. Nasridinov, "Knn-sc: Novel spectral clustering algorithm using k-nearest neighbors," *IEEE Access*, vol. 9, pp. 152616–152627, 2021, doi: 10.1109/ACCESS.2021.3126854.
- [8] G. Shao, L. Tang, and H. Zhang, "Introducing image classification efficacies," *IEEE Access*, vol. 9, pp. 134809–134816, 2021, doi: 10.1109/ACCESS.2021.3116526.
- [9] Y. Guo, S. Han, Y. Li, C. Zhang, and Y. Bai, "K-Nearest Neighbor combined with guided filter for hyperspectral image classification," *Procedia Comput. Sci.*, vol. 129, pp. 159–165, 2018, doi: 10.1016/j.procs.2018.03.066.
- [10] R. Sicre, A. M. Awal, and T. Furon, "Identity Documents Classification as an Image Classification Problem," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 10485 LNCS, pp. 602–613, 2017, doi: 10.1007/978-3-319-68548-9_55.
- [11] R. Prathivi, "Optimasi Algoritme Naive Bayes Untuk Klasifikasi Data Gempa Bumi di Indonesia Berdasarkan Hiposentrum," *Telematika*, vol. 13, no. 1, pp. 36–43, 2020, doi: 10.35671/telematika.v13i1.928.
- [12] A. Islam, S. B. Belhaouari, A. U. Rehman, and H. Bensmail, "K Nearest Neighbor OveRsampling approach: An open source python package for data augmentation," *Softw. Impacts*, vol. 12, no. December 2021, p. 100272, 2022, doi: 10.1016/j.simpa.2022.100272.
- [13] Adhi Setiawan, "Augmentasi Data Pada Computer Vision," *Data Folks Indonesia*, 2021. <https://medium.com/data-folks-indonesia/augmentasi-data-pada-computer-vision-45c5ebe10e8f> (accessed Jun. 16, 2022).
- [14] B. Sandy, J. K. Siahaan, P. Permana, and ..., "Klasifikasi Citra Wayang Dengan Menggunakan Metode k-NN & GLCM," *Semant. (Seminar ...)*, vol. 2, no. November, pp. 71–77, 2019, [Online]. Available: <http://semantika.polgan.ac.id/index.php/Semantika/article/view/48>.
- [15] M. Zhao, X. Zhang, Z. Shi, P. Li, and B. Li, "Restoration of Motion Blurred Images Based on Rich Edge Region Extraction Using a Gray-Level Co-Occurrence Matrix," *IEEE Access*, vol. 6, pp. 15532–15540, 2018, doi: 10.1109/ACCESS.2018.2815608.
- [16] Muhammad Yunus, "Feature Extraction : Gray Level Co-occurrence Matrix (GLCM)," *medium.com*, 2020. <https://yunusmuhammad007.medium.com/feature-extraction-gray-level-co-occurrence-matrix->

- glcm-10c45b6d46a1 (accessed Jun. 16, 2022).
- [17] A. Bablani, D. R. Edla, and S. Dodia, "Classification of EEG data using k-nearest neighbor approach for concealed information test," *Procedia Comput. Sci.*, vol. 143, pp. 242–249, 2018, doi: 10.1016/j.procs.2018.10.392.
- [18] T. Harlina, E. Handayani, M. Informatika, S. Tinggi Ilmu Komputer PGRI Banyuwangi, T. Informatika, and S. A. Tinggi Ilmu Komputer PGRI Banyuwangi Jl Jend Yani No, "Klasifikasi Motif Batik Banyuwangi Menggunakan Metode K-Nearest Neighbor (K-Nn) Berbasis Android," vol. 07, pp. 82–96, 2022, [Online]. Available: <https://jurnal.stkipggritulungagung.ac.id/index.php/jipi/article/view/2411/1127>.
- [19] Y. Kusumawati, A. Susanto, I. Utomo, W. Mulyono, and D. P. Prabowo, "Klasifikasi Batik Kudus Berdasarkan Pola Menggunakan K-NN dan GLCM," *LPPM-Universitas Muhammadiyah Purwokerto*, pp. 509–514, 2020.
- [20] A. Pariyandani, D. A. Larasati, E. P. Wanti, and Muhathir, "Klasifikasi Citra Ikan Berformalin Menggunakan Metode K-NN dan GLCM," *Pros. Semin. Nas. Teknol. Inform.*, vol. 2, no. 1, pp. 42–47, 2019.
- [21] I. G. Wirayudhana, "Klasifikasi Mutu Buah Jambu Biji Getas Merah Berdasarkan Tekstur Menggunakan Grey Level Co-Occurrence Matrix (GLCM) dengan Klasifikasi KNN," *J. Indones. Sos. Teknol.*, vol. 2, no. 6, pp. 953–964, 2021, doi: 10.36418/jist.v2i6.166.
- [22] P. A. Simanungkalit, H. Fitriyah, and E. Setiawan, "Sistem Klasifikasi Telur Ayam Fertile dan Infertile Menggunakan Fitur Tekstur Dan Metode K-Nearest Neighbor Berbasis Raspberry," vol. 5, no. 1, pp. 405–411, 2021, [Online]. Available: <http://j-ptiik.ub.ac.id>.