

Klasifikasi Motif Batik menggunakan metode Deep Convolutional Neural Network dengan Data Augmentation

Samuel Febrian Tumewu¹

Program Studi Informatika
Fakultas Teknologi Industri
Universitas Kristen Petra

Jl. Siwalankerto 121 – 131 Surabaya
60236

Telp. (031) – 2983455, Fax. (031) –
8417658

samueltumewu21@gmail.com¹

Djoni Haryadi Setiabudi²

Program Studi Informatika
Fakultas Teknologi Industri
Universitas Kristen Petra

Jl. Siwalankerto 121 – 131 Surabaya
60236

Telp. (031) – 2983455, Fax. (031) –
8417658

djonihs@petra.ac.id²

Indar Sugiarto³

Program Studi Teknik Elektro
Fakultas Teknologi Industri
Universitas Kristen Petra

Jl. Siwalankerto 121 – 131 Surabaya
60236

Telp. (031) – 2983455, Fax. (031) –
8417658

indi@petra.ac.id³

ABSTRAK

Pada penelitian-penelitian sebelumnya yang bertujuan untuk mengklasifikasikan motif batik umumnya menggunakan motif-motif geometri saja dengan menggunakan *Convolutional Neural Network* (CNN) VGG dan penerapan augmentasi sebatas pada skala dan rotasi. Untuk itu pada penelitian ini akan dilakukan augmentasi yang lebih beragam pada model CNN *Residual Network* (Resnet) dengan objek yang dijadikan penelitian adalah motif geometri dan non-geometri.

Penelitian klasifikasi motif batik ini menggunakan metode CNN dengan arsitektur Resnet untuk mengenali pola pada motif batik. Motif batik yang menjadi objek penelitian ini adalah motif kategori geometri (ceplok, kawung, lereng, nitik, dan parang) dan kategori nongeometri (semen dan lunglungan). Selain itu, pada dataset akan diterapkan augmentasi Scale, Random Erase, Rotation, dan Flip. Augmentasi pada dataset diterapkan guna memperbesar jumlah dan meningkatkan variasi pada dataset batik.

Hasil pengujian menunjukkan CNN dengan penggunaan data augmentation pada training dataset memberikan akurasi hingga 84,52% pada Resnet-18 dan 81,90% pada Resnet-50. Adapun pada penggunaan dataset dengan augmentasi rotation memberikan peningkatan akurasi sebesar 4,06%, augmentasi random erase memberikan peningkatan sebesar 9,38%, augmentasi scale sebesar 6,52%, dan pada augmentasi flip sebesar 8,58%.

Kata Kunci: *Image Classification, Data Augmentation, Convolutional Neural Network, Resnet, Klasifikasi Batik*

ABSTRACT

Related researches before used Convolutional Neural Network (CNN) VGG to classify batik motif which limited only on geometrical pattern and implemented 2 augmentation consist of scale and rotation. Therefore, this research uses CNN Residual Network (Resnet) with 4 augmentation technique on both geometrical and non geometrical batik pattern.

This research use (Resnet) as a main architecture of CNN to identify batik pattern. Batik motives for this research are from geometric category which is ceplok, kawung, lereng, nitik, and parang. And from nongeometri category are semen and lunglungan. Furthermore, the dataset will be applied scale, random erase, rotation, and flip augmentation to increase the quantity and variation of batik dataset.

The results show that CNN Resnet with data augmentation on training dataset gives accuracy up to 84,52% on Resnet-18 and 81,90% on Resnet-50. furthermore, rotation augmentation adds 4,06%, random erase augmentation adds 9,38%, scale augmentation adds 6,52%, and flip augmentation adds 8,58% on accuracy.

Keywords: *Image Classification, Data Augmentation, Convolutional Neural Network, Resnet, Batik Classification*

1. PENDAHULUAN

Batik adalah budaya yang sangat kental di Indonesia, sehingga batik dapat ditemukan di seluruh daerah Nusantara dengan keunikannya masing-masing. Bahkan dunia melalui UNESCO telah mengakui keberadaan batik sebagai warisan budaya dunia pada tanggal 2 Oktober 2009 dengan memasukkan Batik Indonesia kedalam daftar Representatif sebagai Budaya Tak-Benda Warisan Manusia (Representative List of the Intangible Cultural Heritage of Humanity) [13]. Namun pada peringatan hari batik nasional pada tanggal 2 Oktober 2019, Presiden Indonesia – Joko Widodo mengatakan bahwa UNESCO sedang mengevaluasi pengakuan warisan budaya dunia tersebut. Presiden menyampaikan pesan kepada masyarakat Indonesia untuk terus melestarikan batik [11]. Akan tetapi, walaupun orang Indonesia cukup gemar dan sering mengenakan batik, tak sedikit juga yang masih kurang kenal dengan motif yang berada pada produk batik yang digunakan. Salah satu tindakan konkret untuk melestarikan batik adalah dengan mengenal motif-motif pada batik Indonesia.

Penelitian yang berkaitan dengan automatic batik recognition sudah pernah dilakukan sebelumnya mulai dari menggunakan metode-metode pada computer vision hingga implementasi metode deep learning. Metode SIFT (Scale Invariance Feature Transform) digunakan oleh Nurhaidi untuk mengenali pola pada batik [9]. Namun metode SIFT cenderung menghasilkan keypoint - keypoint yang tidak cocok karena sifat dari batik yang berpola simetris dan berulang. Untuk mengatasi permasalahan ini maka pada tahap post-process diterapkan metode Hough Transform voting. Kemudian selain SIFT ada metode state-of-the-art lainnya yang datang dari bidang computer vision yakni SURF (Speeded Up Robust Features). Pada 2017, Karimah menerapkan kombinasi 2 metode untuk feature extraction. Metode SURF untuk mendeteksi keypoint pada gambar lalu dilakukan metode GLCM (Gray Level Co-occurrence Matrix) untuk feature extraction berdasarkan nilai

kecerahan piksel pada gambar [6]. Rerata akurasi yang didapatkan adalah sebesar 95.47% melalui kombinasi SURF dan GLCM dengan klasifikasi KNN (K-Nearest Neighbour) pada $K=3$. Lalu pada 2018, ada penelitian juga yang dilakukan dengan menggabungkan metode feature extraction MTH (Multi Texton Histogram) dengan KNN dan SVM [8]. Hasil akurasi yang didapatkan Classifier KNN adalah 82% sedangkan SVM mendapat nilai 76% dalam mengklasifikasikan batik.

Penelitian-penelitian tersebut memiliki kelebihan masing-masing, karena datang dari 2 bidang yang berbeda yaitu computer vision dan machine learning dan ada juga yang memadukan metode dari 2 bidang tersebut. Namun, metode-metode feature extraction yang diimplementasikan masih dilakukan secara terpisah dengan mesin pengklasifikasian (classifier), dampak buruknya adalah model yang dihasilkan akan kesulitan untuk mengenali motif batik yang baru [1]. Maka pada 2018, Agastya, I. M. A. dan Setyanto, A. melakukan klasifikasi motif batik menggunakan deep learning Convolutional Neural Network (CNN) dengan arsitektur VGG16 dan VGG19. CNN memiliki kelebihan karena bisa memilih feature pada gambar tanpa harus melibatkan peneliti untuk mengembangkan mesin feature extraction. Akan tetapi CNN kesulitan ketika berhadapan dengan data yang memiliki augmentasi beragam (contohnya, skala dan rotasi). Kemudian untuk mengatasi permasalahan ini maka dilakukan data augmentation pada tahap pre-process. Data augmentation yang dilakukan hanya sejauh rotasi dan skala namun hasil akurasi yang didapatkan meningkat sebesar 10% dibanding tanpa melakukan data augmentation.

Jadi, penelitian ini dibuat untuk menerapkan metode CNN dengan arsitektur yang berbeda yaitu, ResNet. Selain rotasi dan skala yang telah dilakukan oleh Agastya, I. M. A. [1], data augmentation pada penelitian ini akan melakukan flipping dan random erasing juga. Selanjutnya, manfaat yang diharapkan yang bisa didapat melalui hasil dari penelitian ini adalah masyarakat Indonesia dapat terbantu untuk mengenali motif-motif batik yang ada di sekitar.

2. DASAR TEORI

2.1 Tinjauan Pustaka

2.1.1 Batik

Motif batik geometri adalah motif yang memiliki ornamen dasar yang tersusun oleh bentuk geometri seperti persegi, layang-layang, atau lingkaran. Contoh 5 motif batik geometri yang juga akan digunakan pada penelitian ini yaitu Ceplok, Kawung, Lereng, Nitik, dan Parang.

Motif ceplok memiliki desain yang didasarkan pada bentuk bintang, mawar, atau bentuk lainnya. Motif kawung merupakan motif yang menyerupai buah kawung (sejenis kelapa atau aren) selain itu juga kadang ditafsirkan menyerupai bunga teratai lotus. Kemudian motif lereng dan parang, kedua motif ini sangat mirip. Persamaan keduanya adalah pada umumnya memiliki motif parang (menyerupai huruf 'S') dan memanjang secara diagonal. Namun pola parang selalu mengandung ragam hias mlinjon sedangkan lereng tidak selalu. Sedangkan motif lereng terdapat garis diagonal yang tidak lebar dan dipenuhi oleh pola-pola kecil. Terakhir adalah motif nitik yang dapat dikenali melalui lingkaran maupun ceplokannya yang tersusun atas banyak garis halus, balok kecil, atau segi empat [10].

Kemudian ada motif batik non geometri, yaitu motif batik yang memiliki susunan bentuk pola yang tidak teratur. Adapun pola hias

yang biasanya ada di motif batik non geometri adalah yang tersusun dari ornamen tumbuhan, candi, binatang dan lainnya. 2 contoh batik non geometri yang juga akan digunakan sebagai objek pada skripsi ini adalah lung-lungan dan semen.

Motif batik lung-lungan memiliki ornamen tumbuhan sebagai ornamen utamanya. Karena Lung-lungan sendiri memiliki arti tunas atau kuncup yang menjalar. Sedangkan motif semen memiliki 3 ornamen. Yaitu ornamen yang berhubungan dengan daratan seperti binatang berkaki empat atau tumbuhan, lalu ornamen kedua yaitu yang berhubungan dengan udara seperti burung garuda atau awan. Kemudian ornamen ketiga berhubungan dengan laut yaitu hewan – hewan air seperti ikan, katak, atau ular.

2.1.2 Convolutional Neural Network

Convolutional Network atau Convolutional Neural Network (CNN) adalah *neural network* spesialisasi untuk memroses data yang memiliki topologi grid. Contohnya seperti data time-series yang merupakan grid 1 dimensi, sedangkan data gambar merupakan grid 2 dimensi dari piksel-piksel yang terkandung di dalamnya [3].

Pada umumnya, CNN memiliki 3 layer utama dalam arsitekturnya yaitu, *Convolutional*, *Pooling*, dan *Fully-Connected* [7].

Pada layer *convolutional* memiliki beberapa neuron yang tersusun sehingga membentuk sebuah *filter*. *Filter* ini akan dioperasikan dengan menggunakan *dot product* terhadap sebagian area pada input gambar yang disebut dengan *receptive field*. Sehingga akan menghasilkan output atau *activation map* atau *feature map*. Jumlah *feature map* yang dihasilkan adalah sebanyak jumlah *filter* yang digunakan.

Sebelumnya, filter ini akan diinisialisasi dengan nilai-nilai tertentu, dan ketika tahap *learning* filter merupakan salah satu parameter yang akan di-*update*. Dimensi dari *feature map* yang dihasilkan bergantung pada variabel W (ukuran Input), N (ukuran filter), P (*zero padding*), dan S (*Stride*)

Kemudian lanjut ke *pooling layer*. *Pooling layer* biasanya berada diantara *convolutional layer* dengan tujuan untuk mereduksi parameter dari *feature map* agar komputasi bisa berjalan semakin cepat tanpa mengorbankan informasi penting yang terkandung dalamnya. Dan tujuan mendasar lainnya adalah untuk mengurangi kemungkinan overfitting. Operasi *pooling* yang populer digunakan adalah *max-pooling*.

Feature map yang dihasilkan masih dalam bentuk array multidimensi sehingga akan dilakukan *flattening* kedalam bentuk vektor sebagai input untuk *Fully Connected Layer* yang kemudian selanjutnya akan ada beberapa *hidden layer*, *activation function*, *output layer*, dan *loss function*.

2.1.3 Augmentasi Data

Deep convolutional neural network bergantung kepada big data untuk menghindari *overfitting*, namun big data belum tentu mudah untuk didapatkan. Sehingga *data augmentation* hadir sebagai solusi untuk meningkatkan ukuran dan kualitas dari *training dataset* yang terbatas [12]. Khususnya untuk tipe data berupa gambar ada beberapa metode augmentasi yang dapat dipertimbangkan


Augmentasi rotasi dapat dilakukan berapapun nilai derajat dengan arah rotasi searah jarum jam atau kebalikannya. Kemudian ada metode *flipping* yang pada umumnya diterapkan pada sumbu x (*flipping horizontally*), metode ini telah terbukti berpengaruh efektif pada *dataset* seperti CIFAR-10, namun tidak memberikan

hasil yang baik pada dataset MINST karena *flipping* menghasilkan informasi yang berbeda dengan data asli pada MINST [2]. Lalu, metode kernel filter, menghasilkan gambar yang semakin tajam atau semakin buram (*blur*). Kernel filter bisa membuat model semakin handala dalam mendeteksi gambar *blur*. Namun menurut Shorten & Khoshgoftaar, 2019 kernel filter lebih cocok diaplikasikan kedalam *network* ketimbang dilakukan pada *dataset* contohnya mengimplementasi *PatchShuffle Regularization* dengan *convolution layer*. Kemudian adalah metode Random erasing bekerja dengan cara melakukan seleksi secara acak pada bagian pada gambar lalu menghapus nilai pikselnya dengan nilai acak. *Random erasing* dapat diaplikasikan untuk semua arsitektur CNN, *parameter learning free*, dan dapat dikombinasikan dengan teknik *data augmentation* lainnya [14]. Dan yang terakhir adalah skala atau zoom yang merupakan salah satu metode untuk menyerupai data-data seperti asli, yang dimana memiliki variasi zoom yang berbeda-beda.

2.1.4 Convolutional Neural Network Residual Network

Deep Residual Network atau *Residual Network* (ResNet) dikembangkan oleh Kaiming He. Melalui penelitian pada 2016 yang berjudul “Deep Residual learning for image recognition” ResNet adalah pemenang dari *ILSVRC 2015 Competition* yang mampu mengungguli arsitektur VGG, GoogleNet, dan lainnya [5]. Ide utama dibalik pengembangan model Resnet adalah untuk mengatasi fenomena *vanishing gradient descent* yang terjadi pada *deep CNN*.

ResNet memodifikasi *network* dengan adanya *identity connection*. *Identity connection* yang membentangi dari input layer hingga output layer disebut sebagai *residual block*, dapat dilihat pada Gambar 1 (sebelah kiri).



Gambar 1. Residual Block [5]

Resnet memiliki 2 jenis *connection* pada *residual block* berdasarkan ukuran dimensi *input* dan *output*. Pertama, adalah *identity shortcut connection*, digunakan apabila *input* dan *output* memiliki dimensi yang sama. Kedua, apabila dimensi *output* lebih besar dari *input*, maka akan ada 2 pilihan *connection* yaitu menggunakan metode *zero-padding* atau *projection shortcut connection*. Adapun metode *zero-padding connection* tidak merupakan *connection* yang tidak memiliki parameter. Sedangkan *projection shortcut connection* memiliki parameter karena menerapkan *convolution layer* ukuran 1 x 1.

Resnet juga mengimplementasi arsitektur *bottleneck* pada bloknya. Contohnya adalah Resnet-50 yang berasal dari Resnet-34 yang mengimplementasi *bottleneck design*. Desain *bottleneck* ini memiliki 3 *layers* pada sebuah *block* seperti yang digambarkan pada Gambar 1 (sebelah kanan). *Kernel filter* berukuran 1 x 1 berperan untuk mengurangi dan mengembalikan dimensi ke semula, diantaranya diterapkan *kernel filter* berukuran 3 x 3

convolution layer. Desain *bottleneck* membuat Conv. Layer 3 x 3 dapat mengerjakan bagiannya dengan tidak memakan *resource* yang besar.

2.2 Tinjauan Studi

Pengklasifikasian motif batik sebelumnya telah dilakukan percobaan oleh Karimah, F. U. [6] dan Minarno, A. E [8]. dalam 2 percobaan ini masing-masing menerapkan metode dari *image processing* untuk mengambil *feature* dari gambar batik. Antara lain adalah dengan metode SURF-GLCM, dan MTH. Setelah itu dilanjutkan dengan menerapkan metode untuk melakukan klasifikasi pada setiap label atau motif batik dengan menggunakan antara lain kNN dan SVM. Percobaan yang dilakukan menggunakan SURF-GLCM dengan kNN mendapat akurasi sebesar 95.47% [6]. Dan pada percobaan MTH dengan SVM-kNN [8] mendapat nilai akurasi sebesar 76%.

Namun, percobaan yang dilakukan sebelumnya memiliki kelemahan dari aspek performa karena metode *feature extractor* dan pengklasifikasian dilakukan secara terpisah. Dan juga perlu melibatkan manusia secara aktif dalam melakukan konfigurasi pada metode *image processing*. Oleh karena itu, pada percobaan berikut yang dilakukan oleh Gultom, Y. [4] dan Agastya, I., M., [1] dilakukan dengan menggunakan metode CNN yang merupakan *feature extractor* sekaligus bisa menambahkan *softmax* sebagai *classifier*. Hasil oleh CNN VGG16 [4] mendapatkan akurasi sebesar 89%. Sedangkan CNN VGG16 beserta penerapan augmentasi pada data [1] mendapat akurasi sebesar 89.3%.

3. DESAIN SISTEM

Proses pembuatan sistem meliputi Augmentasi data, Pembuatan model CNN Resnet, Sistem *training*.

3.1 Augmentasi Data

Dataset pada penelitian ini diambil dari repositori publik github [4]. Namun jumlah gambar masih belum terlalu banyak. Sehingga perlu mengimplementasi Augmentasi pada data gambar untuk meningkatkan kuantitas dataset serta meningkatkan kualitas model dalam mengenali keanekaragaman gambar.

Sebelum dilakukan augmentasi, gambar akan dipotong menjadi 4 bagian. Kemudian masing-masing 4 bagian gambar akan dilakukan *resize* ke ukuran 224 x 224.

Kemudian, akan diterapkan 4 augmentasi data yakni, *rotation*, *random erase*, *scale (zoom in)*, *flip* (berdasarkan sumbu horisontal). Sehingga hasil dari proses ini berupa dataset yang telah terbagi kedalam 4 jenis dataset berdasarkan augmentasi.

Selain 4 augmentasi sebelumnya, dilakukan juga augmentasi dengan menggabungkan 2 metode augmentasi. Sehingga akan ada 6 kombinasi augmentasi campur yaitu, *zoom-randomErase*, *rotate-flip*, *flip-randomErase*, *rotate-zoom*, *rotate-randomErase*, dan *flip-zoom*.

Untuk setiap motif pada *dataset* diberi kode label. Motif Ceplok, Kawung, Lereng, Nitik, Parang, Semen, dan Lunglungan secara berurutan berlabel 1, 2, 3, 4, 5, 6, dan 7.

3.2 Pembuatan Model CNN Resnet

Model CNN Resnet diimplementasikan berdasarkan arsitektur asli [5]. Penelitian ini menggunakan 2 jenis Resnet berdasarkan jumlah

layer yaitu, 18 dan 50. Dengan menggunakan *regularization layer* yaitu *dropout* serta *adam optimizer* dengan *learning rate* 0,001.

Adapun model ini dibangun dengan menggunakan 2 komponen penyusun yakni *residual block* dan *identity block* yang digunakan pada komponen utama Resnet.

3.3 Sistem Training

Sistem *training* membutuhkan dataset dan model. Apabila kedua syarat tersebut memenuhi, maka akan dilanjutkan. Proses dimulai dengan mengambil data pada dataset dan melakukan *preparation data*. Tahap ini dilakukan untuk membuat data kompatibel dengan model yang dibangun pada API Keras dan juga agar data bisa berperan dengan maksimal pada hasil akhir akurasi. Contohnya, dilakukan konversi label data menjadi matriks *one hot encoding* agar bisa kompatibel, serta dilakukan normalisasi pada data dengan menerapkan rentang nilai 0 hingga 1 yang sebelumnya 1 hingga 255.

Setelah data selesai dilakukan pada tahap *preparation data*, selanjutnya adalah melakukan konfigurasi untuk proses *training*. Antara lain adalah menerapkan *checkpoint model* untuk melakukan penyimpanan model ketika pada *epoch* tertentu mendapat nilai *validation accuracy* yang tertinggi. Menerapkan *Earlystopping* untuk langsung memberhentikan proses *training* ketika *validation accuracy* tidak mengalami peningkatan lagi setelah beberapa *epoch*. Serta melakukan konfigurasi pada *hyperparameter epoch* dan *batch size*

Hasil dari proses *training* ini adalah dokumentasi gambar grafik perkembangan nilai *accuracy* dan *loss* pada data *validation* dan *training* bertujuan untuk memberikan informasi terukur tentang seberapa baik model yang dihasilkan. Dan memberikan model dari hasil *training* dalam sebuah file yang memuat informasi keseluruhan dari model (*weights* dan *architecture*).

4. PENGUJIAN SISTEM

Implementasi sistem dijalankan pada komputer dengan menggunakan GPU Geforce RTX 2080 Ti, dan OS CentOS.

Sistem dijalankan dengan menggunakan bahasa pemrograman Python versi 3.6.9. Dengan menggunakan API Keras versi 2.3.1 dan backend dari Tensorflow versi 2.1.0. Beserta beberapa *library* pendukung berupa Numpy versi 1.16.3, Opencv 4.2.0, dan H5py versi 2.10.0.

4.1 Pengujian terhadap berbagai macam dataset

Pengujian dilakukan pada kedua arsitektur CNN Resnet, yaitu Resnet-18 dan Resnet-50. Kedua model akan dilakukan *training* terhadap 5 jenis dataset yang telah dilakukan augmentasi. Setelah itu, akurasi yang dihasilkan akan dibandingkan dengan model yang dilakukan *training* pada *dataset* tanpa augmentasi. Hasil pengujian menunjukkan bahwa penerapan *Random Erase* meningkatkan akurasi sebesar 9,38% pada Resnet-18. Sedangkan pada Resnet-50 akurasi bertambah sebesar 8,58%. Sedangkan augmentasi campur tidak memiliki peningkatan akurasi yang signifikan dibanding yang lain. Tabel 1 merupakan perbandingan akurasi terhadap penerapan arsitektur Resnet dan jenis-jenis *dataset*, angka yang bercetak tebal merupakan akurasi tertinggi di kelompok arsitektur CNN Resnet tersebut.


Tabel 1. Perbandingan Akurasi terhadap penerapan augmentasi

Dataset	Resnet-18 (%)		Resnet-50 (%)	
Tanpa augmentasi	75,14		73,32	
Rotasi	78,57	+3,43	77,38	+4,06
Random Erase	84,52	+9,38	80,00	+6,68
Scale	81,66	+6,52	77,14	+3,82
Flip	82,85	+7,71	81,90	+8,58
Campur	75,71	+0,57	75,95	+2,63

4.2 Pengujian terhadap nilai ROC dan AUC


Produk batik yang beredar sekarang ini kebanyakan memiliki lebih dari 2 motif dasar. Adapun pada batik non geometri yaitu motif semen dan lunglungan memiliki pola yang tidak beraturan. Berdasarkan realita-realita tersebut maka dilakukan pengujian menggunakan nilai ukur dari *Receiver Operating Characteristics* (ROC) dan *Area Under The Curve* (AUC). Adapun AUC yang diterapkan adalah integral dari ROC. ROC dan AUC berperan untuk menghasilkan nilai seberapa yakin model dalam mengklasifikasikan gambar sesuai dengan kelasnya.

Pengujian dilakukan pada model Resnet-18 yang telah dilakukan *training* pada *dataset* dengan augmentasi *random erase*. Gambar 2 menunjukkan hasil dari kurva ROC dan juga memberikan nilai AUC untuk setiap kelas. *Class 3* (motif titik) dan *class 6* (motif lunglungan) merupakan motif yang berada dibawah rata-rata nilai ROC keseluruhan.



Gambar 2. ROC Curve Resnet-18

Selain pengujian pada Resnet-18, dilakukan juga terhadap Resnet-50 yang sebelumnya dilakukan *training* menggunakan *dataset* augmentasi *flip*. Gambar 3 menunjukkan hasil kurva ROC. Pada model ini, *class 0* (motif ceplok) dan *class 6* (motif lunglungan) adalah 2 motif yang berada dibawah kurva.



Gambar 3. ROC Curve Resnet-50

Melalui pengujian ini, dapat dilihat bahwa model Resnet-18 dan Resnet-50 memiliki nilai rata-rata AUC sebesar 0,68 dan 0,66. Adapun motif batik yang kesulitan untuk dikenali pada keduanya adalah motif lunglungan dikarenakan pola yang cukup rumit dan sangat unik antara satu dengan yang lainnya. Sedangkan motif seperti parang dan lereng memiliki AUC diatas 0,70 dikarenakan polanya yang mudah dan sangat mudah untuk dibedakan dengan motif yang lain. Rangkuman nilai AUC untuk setiap motif ditunjukkan pada Tabel 2.

Tabel 2 Nilai AUC untuk setiap motif pada Resnet-18 dan Resnet-50

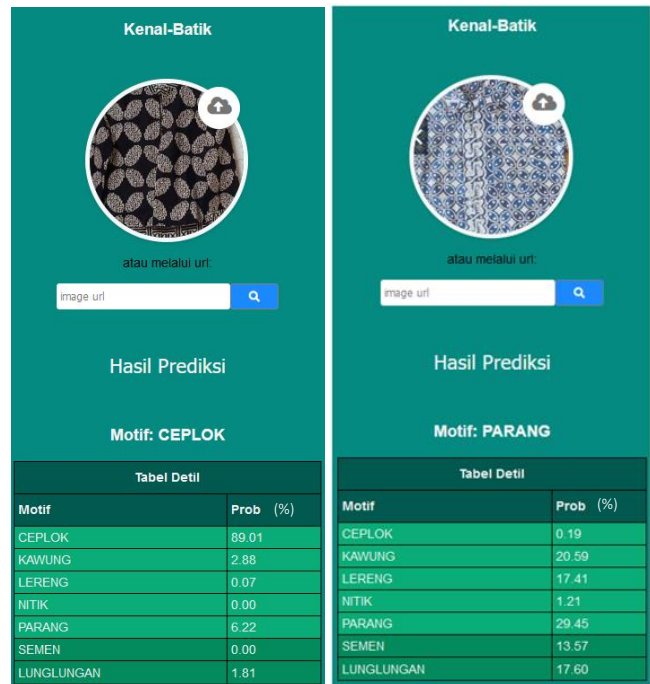
Ket.	Nama Motif	AUC	
		Resnet-18	Resnet-50
Geometri	Ceplok	0,78	0,54
	Kawung	0,68	0,67
	Lereng	0,75	0,73
	Nitik	0,61	0,69
	Parang	0,70	0,71
Non Geometri	Semen	0,55	0,72
	Lunglungan	0,66	0,57

4.3 Pengujian pada aplikasi

Model dengan tingkat akurasi tertinggi dijadikan sebagai *classifier* untuk ditaruh pada *web service* yang kemudian digunakan oleh aplikasi untuk bisa mengklasifikasikan gambar batik.

Pada aplikasi, gambar batik yang dijadikan sebagai *input* akan dilakukan prediksi dan kemudian ditampilkan nama motif yang memiliki skor probabilitas tertinggi beserta distribusi nilai probabilitas pada kelas atau motif lain. Gambar 4 merupakan tampilan aplikasi hasil prediksi gambar batik.

Adapun tantangan yang ditemui yaitu kesalahan dalam mengklasifikasikan batik dikarenakan pola yang dimiliki menganut pola dasar dari motif lain, sehingga akan memunculkan nilai probabilitas yang rendah dan memiliki selisih tipis dengan motif lain. Pada Gambar 4 (bagian kanan) adalah contoh dimana batik kawung dikenali sebagai batik parang dengan selisih skor probabilitas sebesar 8,86%.



Gambar 4. Hasil prediksi pada gambar batik

5. KESIMPULAN

Setelah dilakukan desain, implementasi, dan pengujian sistem maka dapat ditarik beberapa kesimpulan sebagai berikut:

- Akurasi CNN Resnet-18 tanpa menggunakan data augmentation memberikan akurasi sebesar 75,14% pada Resnet-18 dan 73,32% pada Resnet-50.
- *Rotation Data Augmentation* memberikan peningkatan akurasi sebesar 3,43% (Resnet-18) dan 4,06% (Resnet-50)
- *Random Erase Data Augmentation* memberikan peningkatan akurasi sebesar 9,38% (Resnet-18) dan 6,68% (Resnet-50)
- *Scale Data Augmentation* memberikan peningkatan akurasi sebesar 6,52% (Resnet-18) dan 3,82% (Resnet-50)
- *Flip Data Augmentation* memberikan peningkatan akurasi sebesar 7,71% (Resnet-18) dan 8,58% (Resnet-50)
- CNN dengan penggunaan *data augmentation* pada *training dataset* memberikan rata-rata akurasi sebesar 80,66% pada Resnet-18 dan sebesar 78,47% pada Resnet-50.
- AUC terhadap masing-masing motif mayoritas mendapat nilai dibawah 0,70. Hal ini terjadi dikarenakan pola pada motif batik yang sangat beragam dan unik.

Dengan adanya beberapa kesimpulan diatas ada beberapa hal yang dijadikan saran untuk pengembangan dan penyempurnaan selanjutnya antara lain:

- Melakukan variasi pada metode dengan menggunakan metode *objek detection* agar bisa mengenali beberapa motif batik dalam satu gambar.
- Menambahkan augmentasi yang lebih relevan dengan gambar batik yang beredar saat ini.

6. REFERENSI

- [1] Agastya, I. M. A., & Setyanto, A. 2018. Classification of Indonesian Batik Using Deep Learning Techniques and Data Augmentation. *2018 3rd International Conference on Information Technology, Information System and Electrical Engineering (ICITISEE)*. doi: 10.1109/icitisee.2018.8720990.
- [2] Cubuk, E. D., Zoph, B., Mane, D., Vasudevan, V., & Le, Q. V. 2019. Autoaugment: Learning augmentation strategies from data. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 113-123).
- [3] Goodfellow, I., Bengio, Y., & Courville, A. 2017. *Deep learning*. Cambridge, MA: MIT Press.
- [4] Gultom, Y., Arymurthy, A. M., & Masikome, R. J. 2018. Batik Classification using Deep Convolutional Network Transfer Learning. *Jurnal Ilmu Komputer Dan Informasi*, 11(2), 59. doi: 10.21609/jiki.v11i2.507.
- [5] He, K., Zhang, X., Ren, S., & Sun, J. 2016. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. doi: 10.1109/cvpr.2016.90.
- [6] Karimah, F. U., & Harjoko, A. 2017. Classification of Batik Kain Besurek Image Using Speed Up Robust Features (SURF) and Gray Level Co-occurrence Matrix (GLCM). *Communications in Computer and Information Science Soft Computing in Data Science*, 81–91. doi: 10.1007/978-981-10-7242-0_7.
- [7] Li, F. F., Johnson, J., Yeung, S. 2019. CS231n: Convolutional neural networks for visual recognition. *University Lecture*.
- [8] Minarno, A. E., Maulani, A. S., Kurniawardhani, A., Bimantoro, F., & Suciati, N. 2018. Comparison of Methods for Batik Classification Using Multi Texton Histogram. *TELKOMNIKA (Telecommunication Computing Electronics and Control)*, 16(3), 1358. doi: 10.12928/telkomnika.v16i0.7376.
- [9] Nurhaida, I., Noviyanto, A., Manurung, R., & Arymurthy, A. M. 2015. Automatic Indonesians Batik Pattern Recognition Using SIFT Approach. *Procedia Computer Science*, 59, 567–576. doi: 10.1016/j.procs.2015.07.547.
- [10] Paluseri, D. D. 2018. *Penetapan warisan budaya takbenda Indonesia tahun 2018*. Jakarta: Direktorat Warisan dan Diplomasi Budaya Direktorat Jenderal Kebudayaan Kementerian Pendidikan dan Kebudayaan.
- [11] Redaksi CNBC Indonesia. 2019, October 2. Jokowi: UNESCO Mulai Evaluasi Pengakuan Batik Warisan Dunia. Retrieved November 13, 2019, from <https://www.cnbcindonesia.com/news/20191002142847-4-103878/jokowi-unesco-mulai-evaluasi-pengakuan-batik-warisan-dunia>.
- [12] Shorten, C., & Khoshgoftaar, T. M. 2019. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). doi: 10.1186/s40537-019-0197-0.
- [13] Suryanto. 2009, October 2. Batik Indonesia Resmi Diakui UNESCO. Retrieved November 22, 2019, from <https://www.antarane.ws.com/berita/156389/batik-indonesia-resmi-diakui-unesco>.
- [14] Zhong, Z., Zheng, L., Kang, G., Li, S., & Yang, Y. 2017. Random erasing data augmentation. *arXiv preprint arXiv:1708.04896*.