

**TESIS**

**KLASIFIKASI MOTIF BATIK PAPUA MENGGUNAKAN  
DEEP LEARNING**



Disusun oleh:

**Nama : Suhardi Aras**  
**NIM : 19.77.1172**  
**Konsentrasi : Business Intelligence**

**PROGRAM STUDI PJJ S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2022**

**TESIS**

**KLASIFIKASI MOTIF BATIK PAPUA  
MENGUNAKAN DEEP LEARNING**

**CLASSIFICATION OF PAPUAN BATIK MOTIFS USING  
DEEP LEARNING**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

**Nama : Suhardi Aras**  
**NIM : 19.77.1172**  
**Konsentrasi : Business Intelligence**

**PROGRAM STUDI PJJ S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2022**

**HALAMAN PENGESAHAN**

**KLASIFIKASI MOTIF BATIK PAPUA  
MENGUNAKAN DEEP LEARNING**

**CLASSIFICATION OF PAPUAN BATIK MOTIFS USING  
DEEP LEARNING**

Dipersiapkan dan Disusun oleh

**Suhardi Aras**

**19.77.1172**

Telah Ditujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi PJJ S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Selasa, tanggal 6 Desember 2022

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, tanggal 6 Desember 2022

**Rektor**

**Prof. Dr. M. Suryanto, M.M.**

**NIK. 190302001**

**HALAMAN PERSETUJUAN**

**KLASIFIKASI MOTIF BATIK PAPUA  
MENGUNAKAN DEEP LEARNING**

**CLASSIFICATION OF PAPUAN BATIK MOTIFS USING  
DEEP LEARNING**

Dipersiapkan dan Disusun oleh

**Suhardi Aras**

**19.77.1172**

Telah Ditujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi PJJ S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Selasa, tanggal 6 Desember 2022

**Pembimbing Utama**

**Anggota Tim Penguji**

**Dr. Arief Setyanto, S.Si., M.T**  
**NIK. 190302036**

**Dr. Andi Sunyoto, M.Kom.**  
**NIK. 190302052**

**Pembimbing Pendamping**

**Alva Hendi Muhammad, S.T., M.Eng., Ph.D.**  
**NIK. 190302493**

**Ir. Rismayani, S.Kom, M.T., CHSA**  
**NIK. 190302569**

**Dr. Arief Setyanto, S.Si., M.T**  
**NIK. 19032036**

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer.

Yogyakarta, 6 Desember 2022  
**Direktur Program Pascasarjana**

**Dr. Kusriani, M.Kom.**  
**NIK. 190302106**

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

**Nama mahasiswa : Suhardi Aras**  
**NIM : 19.77.1172**  
**Konsentrasi : Business Intelligence**

Menyatakan bahwa Tesis dengan judul berikut:

### **KLASIFIKASI MOTIF BATIK PAPUA MENGGUNAKAN DEEP LEARNING**

Dosen Pembimbing Utama : Dr.Arief Setyanto, S.Si., M.T  
Dosen Pembimbing Pendamping : Ir. Rismayani, S.Kom., M.T., CIISA

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, tanggal 6 Desember 2022

Yang Menyatakan,



Suardi Aras

## HALAMAN PERSEMBAHAN

Karya ini dipersembahkan untuk kedua Almarhum orang tua saya, semoga kebaikan atas ilmu ini menjadi pahala atas mereka, juga kepada Ratih Mayaningrum sebagai istri saya dan anak – anak saya , atas pengertian dan dukungan selama proses perkuliahan dan penyusunan tesis ini.



## KATA PENGANTAR

Alhamdulillah, telah sampai pada proses ini, selain itu penulis mengucapkan terima kasih kepada sebesar – besarnya kepada Direktur Program Pascasarjana Prof. Dr. Kusriani, M.Kom, Dosen Pembimbing Dr. Arief Setyanto, S.Si., M.T dan Ir. Rismayani S.Kom., M.T., CIISA, serta review dan masukan dari dosen penguji dalam memperkaya hasil penelitian tesis ini.

Ucapan terima kasih disampaikan kepada Rektor Universitas Muhammadiyah Sorong dan Dekan Fakultas Teknik yang telah memberi dukungannya dalam mengambil dan menyelesaikan studi ini.

Hatur terima kasih disampaikan pula kepada jajaran pimpinan Kantor Perwakilan SKK Migas Wilayah Papua dan Maluku di Sorong yang mendukung dan memberi ruang dalam mengikuti perkuliahan dan penyelesaian penelitian ini.

Terutama juga ungkapan terima kasih kepada istri dan anak – anak yang memberi ruang dan waktu dalam penyelesaian perkuliahan dan penelitian ini. Dan proses belajar ini bisa menjadi inspirasi bagi anak – anak saya bahwa menjadi pelajar dan belajar itu tidak mengenal usia.

Yogyakarta, 6 Desember 2022

Penulis

## DAFTAR ISI

|  |      |
|--|------|
| HALAMAN JUDUL.....                     | ii   |
| HALAMAN PENGESAHAN.....                | iii  |
| HALAMAN PERSETUJUAN.....               | iv   |
| HALAMAN PERNYATAAN KEASLIAN TESIS..... | v    |
| HALAMAN PERSEMBAHAN.....               | vi   |
| KATA PENGANTAR.....                    | vii  |
| DAFTAR ISI.....                        | viii |
| DAFTAR TABEL.....                      | xi   |
| DAFTAR GAMBAR.....                     | xii  |
| INTISARI.....                          | xii  |
| <i>ABSTRACT</i> .....                  | xvi  |
| BAB I PENDAHULUAN.....                 | 1    |
| 1.1. Latar Belakang Masalah.....       | 1    |
| 1.2. Rumusan Masalah.....              | 6    |
| 1.3. Batasan Masalah.....              | 6    |
| 1.4. Tujuan Penelitian.....            | 6    |
| 1.5. Manfaat Penelitian.....           | 7    |
| 1.6. Hipotesis.....                    | 7    |
| BAB II TINJAUAN PUSTAKA.....           | 8    |
| 2.1. Tinjauan Pustaka.....             | 8    |
| 2.2. Keaslian Penelitian.....          | 13   |



|  |           |
|--|-----------|
| 2.3. Landasan Teori.....   | 18        |
| 2.3.1 BATIK.....   | 18        |
| 2.3.2 Klasifikasi.....   | 18        |
| 2.3.3 Convolution Neural Network.....                            | 19        |
| 2.3.4 Deep Learning.....   | 19        |
| 2.3.5 Transfer Learning.....                                     | 20        |
| 2.3.6 Data Augmentation.....                                     | 21        |
| 2.3.7 Arsitektur VGG16.....                                      | 22        |
| 2.3.8 Arsitektur Resnet50.....                                   | 23        |
| 2.3.9 Evaluasi Model.....  | 24        |
| <b>BAB III METODE PENELITIAN.....</b>                            | <b>25</b> |
| 3.1. Jenis, Sifat, dan Pendekatan Penelitian.....                | 25        |
| 3.2. Dataset yang digunakan.....                                 | 25        |
| 3.3. Metode Transfer Learning.....                               | 28        |
| 3.4. Metode Analisis Data.....                                   | 29        |
| 3.5. Perbandingan Model dengan Dataset lain.....                 | 29        |
| 3.6. Alur Penelitian.....  | 30        |
| <b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....</b>               | <b>33</b> |
| 4.1. Pre-processing Data.....                                    | 33        |
| 4.2. Hasil Pemrosesan Data.....                                  | 34        |
| 4.2.1 Hasil training dan validasi VGG 16 tanpa Augmentasi.....   | 35        |
| 4.2.2 Hasil training dan validasi Resnet50 tanpa Augmentasi..... | 35        |
| 4.2.3 Hasil training dan testing VGG16 dengan Augmentation.....  | 36        |

|   |           |
|---|-----------|
| 4.2.4. Hasil training dan validasi Resnet50 dengan Augmentation.....                          | 47        |
| 4.3. Perbandingan Kinerja.....  | 58        |
| 4.4. Evaluasi Model .....   | 62        |
| 4.4.1. Perbandingan Confusion Matrix pada Model VGG16 dan RestNet50<br>tanpa Augmentasi ..... | 62        |
| 4.4.2. Perbandingan Confusion Matrix pada Model VGG16 dengan<br>Augmentation.....             | 63        |
| 4.4.3. Perbandingan Confusion Matrix pada Model VGG16 dengan<br>Kombinasi Augmentation .....  | 65        |
| 4.4.4. Perbandingan Confusion Matrix pada Model RestNet50 dengan<br>Augmentation.....         | 66        |
| 4.4.5. Perbandingan Confusion Matrix pada Model ResNet50 dengan<br>Kombinasi Augmentasi.....  | 67        |
| 4.5. Perbandingan Evaluasi Model .....  | 68        |
| 4.6. Perbandingan model dengan penelitian sebelumnya .....                                    | 70        |
| <b>BAB V PENUTUP</b> .....  | <b>74</b> |
| 5.1. Kesimpulan .....   | 74        |
| 5.2. Saran .....  | 74        |
| <b>DAFTAR PUSTAKA</b> .....   | <b>75</b> |
| <b>LAMPIRAN</b> .....   | <b>79</b> |

## DAFTAR TABEL


|   |    |
|---|----|
| Tabel 2. 1 Matriks literatur review dan posisi penelitian Tuliskan Judul Tesis di Baris Ini ..... | 13 |
| Tabel 2. 2 Confusion Matrix .....   | 24 |
| Tabel 3. 1 Tabel data motif batik .....   | 26 |
| Tabel 4. 1 Nilai augmentasi data .....  | 34 |
| Tabel 4. 2 Pengujian arsitektur tanpa proses augmentasi .....                                     | 58 |
| Tabel 4. 3 Pengujian arsitektur VGG16 menggunakan operasi augmentasi.....                         | 59 |
| Tabel 4. 4 Pengujian arsitektur VGG16 dengan kombinasi atau gabungan operasi augmentasi .....     | 60 |
| Tabel 4. 5 Pengujian arsitektur ResNet50 menggunakan operasi augmentasi.....                      | 60 |
| Tabel 4. 6 Pengujian arsitektur RestNet50 dengan kombinasi atau gabungan operasi augmentasi.....  | 61 |
| Tabel 4. 7 Performance Matriks Model VGG16 dan RestNet 50 tanpa Augmentasi .....                  | 69 |
| Tabel 4. 8 Performance Matriks Model VGG16 dengan Augmentasi.....                                 | 69 |
| Tabel 4. 9 Performance Matriks Model VGG16 dengan kombinasi augmentasi .                          | 69 |
| Tabel 4. 10 Performance Matriks Model RestNet50 dengan Augmentasi.....                            | 69 |
| Tabel 4. 11 Performance Matriks Model RestNet50 dengan kombinasi augmentasi .....                 | 69 |
| Tabel 4. 12 Perbandingan Analisis Terhadap Penelitian Sebelumnya.....                             | 71 |
| Tabel 4. 13 Dataset Motif Batik.....  | 72 |
| Tabel 4. 14 Hasil Pengujian .....   | 72 |

## DAFTAR GAMBAR

|  |    |
|--|----|
| Gambar 2. 1 Layer VGG16.....                                       | 22 |
| Gambar 2. 2 Diagram Blok Algoritma Resnet50.....                   | 23 |
| Gambar 3. 1 Beberapa Contoh Dataset Motif.....                     | 27 |
| Gambar 3. 2 Augmentasi Dataset.....                                | 28 |
| Gambar 3. 3 Alur Penelitian.....                                   | 32 |
| Gambar 4. 1 Pembagian Dataset.....                                 | 33 |
| Gambar 4. 2 Training on VGG16 tanpa Augmentasi.....                | 35 |
| Gambar 4. 3 Training on ResNet50 tanpa Augmentasi.....             | 36 |
| Gambar 4. 4 Hasil Random Affine.....                               | 37 |
| Gambar 4. 5 Training on VGG16 dengan Random Affine.....            | 38 |
| Gambar 4. 6 Training on VGG16 dengan Grayscale.....                | 38 |
| Gambar 4. 7 Hasil Flip.....  | 39 |
| Gambar 4. 8 Training on VGG16 dengan flip.....                     | 40 |
| Gambar 4. 9 Hasil Invert.....                                      | 40 |
| Gambar 4. 10 Training on VGG16 dengan invert.....                  | 41 |
| Gambar 4. 11 Hasil Colorjitter.....                                | 42 |
| Gambar 4. 12 Training on VGG16 dengan ColorJitter.....             | 42 |
| Gambar 4. 13 Training on VGG16 dengan resize.....                  | 43 |
| Gambar 4. 14 Training on VGG16 dengan rotation.....                | 44 |
| Gambar 4. 15 Training on VGG16 dengan Kombinasi Augmentasi I.....  | 45 |
| Gambar 4. 16 Training on VGG16 dengan Kombinasi Augmentasi II..... | 46 |
| Gambar 4. 17 Hasil Penggabungan Kombinasi I dan II.....            | 46 |

|   |    |
|---|----|
| Gambar 4. 18 Training on VGG16 dengan Penggabungan Kombinasi I dan II ... | 47 |
| Gambar 4. 19 Hasil <i>RandomAffine</i> .....                              | 48 |
| Gambar 4. 20 Training on RestNet50 dengan Random Affine.....              | 49 |
| Gambar 4. 21 Training on RestNet50 dengan Grayscale.....                  | 49 |
| Gambar 4. 22 Hasil <i>flip</i> .....                                      | 50 |
| Gambar 4. 23 Training on RestNet50 dengan flip.....                       | 50 |
| Gambar 4. 24 Hasil <i>Invert</i> .....                                    | 51 |
| Gambar 4. 25 Training on RestNet50 dengan Invert.....                     | 51 |
| Gambar 4. 26 Hasil <i>ColorJitter</i> .....                               | 52 |
| Gambar 4. 27 Training on RestNet dengan Colorjitter.....                  | 53 |
| Gambar 4. 28 Training on RestNet dengan Resize.....                       | 53 |
| Gambar 4. 29 Hasil <i>rotation</i> .....                                  | 54 |
| Gambar 4. 30 Training on RestNet50 dengan Rotation.....                   | 54 |
| Gambar 4. 31 Hasil kombinasi Augmentasi I.....                            | 55 |
| Gambar 4. 32 Training on RestNet50 dengan Kombinasi I.....                | 56 |
| Gambar 4. 33 Hasil Kombinasi Augmentasi II.....                           | 56 |
| Gambar 4. 34 Training on RestNet50 dengan Kombinasi II.....               | 57 |
| Gambar 4. 35 Hasil Penggabungan Kombinasi I dan II.....                   | 57 |
| Gambar 4. 36 Training on VGG16 dengan Penggabungan Kombinasi I dan II     | 58 |
| Gambar 4. 37 Confusion Matrix VGG16 dan Resnet Tanpa Augmentation .....   | 62 |
| Gambar 4. 38 Confusion Matrix VGG16 dengan Augmentasi.....                | 64 |
| Gambar 4. 39 Confusion Matrix VGG16 dengan kombinasi Augmentasi .....     | 65 |
| Gambar 4. 40 Confusion Matrix RestNet50 dengan Augmentasi.....            | 66 |

|  |    |
|--|----|
| Gambar 4. 41 Confusion Matrix RestNet50 dengan Augmentasi Rotation.....              | 67 |
| Gambar 4. 42 Confusion Matrix RestNet50 dengan Kombinasi I dan Kombinasi II<br>..... | 67 |
| Gambar 4. 43 Confusion Matrix RestNet50 dengan Kombinasi III .....                   | 68 |



## INTISARI

Motif Batik Papua mulai muncul pada tahun 1984 dan hanya dikenal secara umum dengan satu sebutan yaitu batik Papua, padahal berbagai motif tersebut dapat diklasifikasikan menurut daerah asal pembuatan, budaya dan flora fauna yang memiliki makna, kearifan lokal masyarakat. Kemampuan mengenali setiap motif batik dari Papua membutuhkan pengalaman dan pengetahuan dari kalangan tertentu, agar pengetahuan dan makna tetap terjaga, diperlukan suatu alat yang dapat mengklasifikasikan berbagai motif batik dari Papua. Penelitian ini menggunakan empat kelas dataset yaitu Motif Cendrawasih, Motif Raja Ampat, Motif Tifa Honai dan Motif Asmat yang bersifat non-geometris. Diusulkan untuk mengklasifikasikan motif-motif tersebut menggunakan deep learning menggunakan arsitektur Vgg16 dan Resnet50 dengan fine tuning, untuk menambah data dengan berbagai kombinasi agar diperoleh performa yang lebih baik. Hasil pengujian menunjukkan bahwa tanpa augmentasi data pada arsitektur VGG16 diperoleh akurasi sebesar 62.61% dan arsitektur Resnet50 diperoleh akurasi sebesar 77.27% dengan beberapa kombinasi teknik augmentasi memberikan hasil yang lebih baik tanpa augmentasi data dengan hasil tertinggi pada VGG16 arsitektur memberikan hasil 86.36% dengan teknik augmentasi resize dan pada arsitektur Resnet50 memberikan hasil 86.36% dengan teknik augmentasi kombinasi resize, rotation dan flip.

Kata kunci— deep learning, transfer learning , Augmentasi Data, Batik Papua

## *ABSTRACT*

Papuan batik motifs began to appear in 1984 and are only known in general by one name, namely Papuan batik, even though these various motifs can be classified according to the region of origin, culture and flora and fauna that have meaning. local wisdom of the community. The ability to recognize each batik motif from Papua requires experience and knowledge from certain circles, so that knowledge and meaning are maintained, a tool is needed that can classify various batik motifs from Papua. This study uses four classes of datasets namely Cendrawasih motifs, Raja Ampat motifs, Tifa Honai motifs and Asmat motifs which are non-geometric in nature. It is proposed to classify these motifs using deep learning using Vgg16 and Resnet50 architectures with fine tuning, to add data with various combinations to obtain better performance. The test results show that without data augmentation on the VGG16 architecture an accuracy of 62.61% is obtained and on the Resnet50 architecture an accuracy of 77.27% is obtained with several combinations of augmentation techniques giving better results without data augmentation with the highest results on the VGG16 architecture providing 86.36% results with the resize augmentation technique and on the Resnet50 architecture it gives a result of 86.36% with the augmentation technique a combination of resize, rotation and flip.

**Keywords**—deep learning, transfer learning, data augmentation, Papuan batik



# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Batik sebagai sebuah karya seni asli warisan budaya Indonesia telah diakui oleh UNESCO pada tahun 2009, dengan kekayaan dalam motif dan warna yang dapat dibedakan berdasarkan daerah asal pembuatan atau motif. Motif merupakan suatu dasar atau pokok suatu pola gambar merupakan pusat suatu rancangan gambar sehingga makna dari tanda, simbol atau lambang, dibalik motif tersebut dapat diungkap (Farida & Muhima, 2018) salah satunya adalah Batik Papua yang baru mulai dikenal pada tahun 1984 (Marthen & Mambraku, 2014). Ada beberapa objek budaya yang biasa dijadikan motif batik antara lain patung korwar, rumah adat, tifa, busur panah dan patung asmat. Motif flora dan fauna pun hadir dalam bentuk motif anggrek, burung cendrawasih, cicak, bunga dan buaya (Azhari & Sulistiyawati, 2019). Saat ini, umumnya batik dengan motif seperti disebut sebelumnya dilabelkan hanya dengan satu nama yaitu batik Papua padahal keragaman motif ini dibedakan dari asal wilayah pembatik dan kearifan lokalnya, seperti batik port-numbay, batik sentani, batik asmat dari Suku Asmat, batik komoro dari Suku, batik raja ampat, dan tiap daerahpun mulai mengeksplorasi kebudayaan masing - masing dituangkan dalam batik (Marthen & Mambraku, 2014). Kemampuan mengenal ragam motif dan corak ini membutuhkan pengalaman dan hanya pada kalangan tertentu yang memiliki pengetahuan tersebut, agar kemampuan itu tidak hilang dan dapat digunakan

oleh masyarakat awam maka dibutuhkan tools yang dapat digunakan mengenal dan mengklasifikasi motif batik dari Papua. Kemajuan computer vision saat ini salah satunya melalui metode *Deep Learning* dapat melakukan tugas klasifikasi motif batik dari Papua tersebut

*Deep learning* merupakan bagian dari Machine Learning yang saat ini sedang dikembangkan, dengan meniru konsep kerja dasar jaringan saraf tiruan dengan lapisan yang lebih banyak yang digunakan antara lapisan masukan dan keluaran. Dengan faktor komputansi, dataset yang besar dan baerbagai algoritma yang dilatih lebih dalam menjadikan *deep learning* memberikan kinerja yang semakin lebih baik. Metode yang sering digunakan adalah metode *Convolutional Neural Network (CNN)*. CNN adalah pengembangan dari Multilayer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi, CNN memiliki kedalaman jaringan yang tinggi dan banyak diapliaksi pada data citra (Eka Putra, 2016).

Penelitian yang memanfaatkan deep learning telah banyak dilakukan dalam pengolahan gambar dalam mengenal kembali motif atau corak batik, menggunakan algoritma CNN dalam mengklasifikasi motif batik yang dikombinasikan dengan Grayscale memberikan hasil ujicoba nilai akurasi yang beda antara menggunakan CNN dan kombinasi CNN dengan Grayscale, akurasi menggunakan CNN adalah sebesar 65% sedangkan kombinasi CNN dengan Grayscale memberikan akurasi yaitu 70%, hasil ini menunjukkan warna batik memiliki pengaruh pada kinerja klasifikasi citrak batik berbasis CNN (Mawan, 2020). Penelitian lain yang mengembangkan proses klasifikasi menggunakan

CNN menggunakan arsitektur *GoogLeNet* dan *Residual Network* menunjukkan bahwa arsitektur *GoogLeNet* dan *Residual Network* membutuhkan waktu komputansi yang lebih lama sehingga proses eksekusi lebih lambat dibandingkan dengan arsitektur IncRes-2 yang mampu mengklasifikasi motif batik dengan akurasi dan komputansi yang lebih baik (Wicaksono et al., 2017). Penelitian lain yang melakukan klasifikasi motif batik menggunakan CNN dengan arsitektur VGC-16 dan VGC-19 dengan memanfaatkan *data augmentation* telah memberikan peningkatan akurasi hingga 9% dan akurasi classifier *non-augmentaed* berkurang hingga 21%, hal ini dapat disimpulkan berarti VGC-16 atau VGC-19 berkinerja lebih baik pada data yang diputar daripada data yang dibesarkan, penelitian belum dapat menggeneralisir model pada dataset non – split dan akurasi yang diperoleh masih rendah disebabkan terjadi overfitting antara data latih dengan data training, pengukuran kinerja classifier akan lebih baik jika menggunakan dataset yang sama (Agastya & Setyanto, 2018), pada penelitian klasifikasi batik lain yang menggunakan model arsitektur VGG16 dapat ditingkatkan mencapai 98,96% dengan melakukan augmentasi data dari yang sebelumnya 95,83% tanpa augmentasi data. Augmentasi data yang digunakan dalam penelitian ini menggunakan 8 (delapan) jenis augmentasi yang dikelompokkan menjadi 2 (dua) kombinasi yang akan menambahkan data yang awalnya 50 gambar pada tiap kelas pada 5 kelas batik dan setelah augmentasi menjadi 100 gambar pada tiap kelasnya. (Khasanah et al., 2020). Penelitian lain yang memanfaatkan feature augmentasi data menggunakan arsitektur Resnet50, yang memberikan penambahan dari

dataset asli sebanyak 300 buah gambar memperoleh 1200 buah gambar hasil dari 4 (empat) jenis augmentasi data yaitu memperbesar, memutar, horizontal dan vertical clip. Hasil accuracy yang diperoleh mencapai 96% dan menunjukkan skema augmentasi data memberikan hasil yang baik. (Negara et al., 2021).

Penelitian lain yang memanfaatkan pre-trained transfer learning pada arsitektur CNN MobileNetV2 dalam mengklasifikasikan batik tulis ataupun batik cetak, memberikan akurasi pada training sekitar 96,91%, dan akurasi pada validasi sebesar 94,74%. Saat pengujian dengan data yang belum dikenali model memberikan akurasi 87,5%. Penelitian ini menggunakan 566 image sebagai dataset yang dibagi menjadi 3 bagian yaitu 80% untuk training, 10% untuk validasi dan 10% untuk testing sehingga dari komposisi tersebut diperoleh dataset training adalah 248 batik tulis dan 205 batik cetak, dataset validasi adalah 31 batik tulis dan 26 batik cetak dan dataset pengujian adalah 31 batik tulis dan 25 batik cetak. Dengan dataset yang tidak besar ini untuk mencegah terjadinya overfitting dan menambah variasi data, penelitian ini melakukan augmentasi data secara realtime sehingga tidak mengubah keaslian datanya. Transformasi image yang dilakukan meliputi rotasi, zoom, geser, flip horizontal dan merubah ukuran image dengan memanfaatkan Image Data Generator milik API Keras. Dalam penelitian ini menyimpulkan bahwa augmentasi data menambahkan akurasi pada dataset yang terbatas (Putra et al., 2021).

Teknik *Transfer Learning* memberikan kemudahan untuk dataset yang tidak banyak, dengan memanfaatkan model CNN yang telah dilatih dengan dataset yang banyak dan memanfaatkan layer klasifikasi menyesuaikan bobot dataset yang baru, sehingga tidak membutuhkan waktu yang lama dalam training data. Selain teknik transfer learning, penelitian ini memanfaatkan data augmentasi dalam improvisasi training data, augmentasi data akan membuat data baru dengan melakukan transformasi dari data sebelumnya, transformasi image yang dilakukan dapat dalam *rescaling, rotation, flipping, cropping* dan lainnya (Xue et al., 2016). Dataset dalam penelitian akan mengumpulkan image batik dari beberapa klasifikasi motif dan daerah asal pembatik di Provinsi Papua dan Papua Barat, yang akan disusun dalam beberapa kelas. Minimal masing - masing kelas dapat diperoleh 50 image batik dengan jumlah 4 kelas yaitu batik Asmat, batik Raja Ampat, batik Cendrawasih dan batik Tifa Honai. Jumlah kelas batik dari Papua mungkin saja akan berkembang dengan eksplorasi pada beberapa motif dan daerah lain di wilayah Papua dan Papua Barat. Dari jumlah dataset yang nanti ada, akan dilakukan pre-processing data menggunakan 8 type augmentasi image sehingga dapat menambahkan jumlah dataset untuk ditraining. Pengujiannya akan membandingkan akurasi dari model augmentasi data yang telah dilakukan. Selain menemukan model dalam klasifikasi batik dari Papua, tantangan dalam penelitian ini masih sulit ditemukannya dataset batik dari Papua, sehingga penelitian ini diharapkan dapat memberikan sumbangan dalam terbentuknya dataset klasifikasi motif batik dari Papua.

## 1.2. Rumusan Masalah

Untuk menganalisa klasifikasi motif batik, ada beberapa rumusan masalah yang digunakan sebagai berikut :

- a. Bagaimana teknik *transfer learning* mengoptimalkan model dengan dataset yang tersedia
- b. Jenis teknik data augmentasi mana yang dapat meningkatkan akurasi klasifikasi batik ?

## 1.3. Batasan Masalah

Batasan dari penelitian yang dilakukan oleh penuli adalah sebagai berikut :

- a. Penelitian ini dibatasi dengan dataset yang memuat 4 kelas batik dari Papua
- b. Proses training dengan metode transfer learning melalui fine-tuning pada model arsitektur VGG16 dan Resnet50

## 1.4. Tujuan Penelitian

Tujuan penelitian yang dilakukan oleh penulis adalah sebagai berikut :

- a. Mengimplementasikan metode klasifikasi batik menggunakan metode transfer learning dengan arsitektur Vgg16 dan Resnet50.
  - b. Memperoleh model augmentasi image yang meningkatkan akurasi klasifikasi image
  - c. Mengevaluasi akurasi yang dihasilkan dari metode klasifikasi batik yang digunakan
- a. Terbentuknya dataset yang memuat motif batik dari Papua

### 1.5. Manfaat Penelitian

Hasil penelitian ini diharapkan dapat berkontribusi dalam variant model pengenalan klasifikasi motif batik secara system dan mendorong adanya upaya dalam mendokumentasikan motif batik dari Papua yang merupakan budaya dan kearifan local

### 1.6. Hipotesis

Berdasarkan perumusan masalah yang telah diungkap, maka kesimpulan sementara yang dapat ditarik adalah dengan transfer learning yang digunakan dapat melakukan klasifikasi batik dan memberikan akurasi yang baik. Adapun hipotesa masalah yang mungkin terjadi pada penelitian ini adalah :

- H0 : klasifikasi batik dapat dilakukan menggunakan metode transfer learning dengan data augmentation
- H1 : metode transfer learning dengan data augmentation yang digunakan memberikan akurasi yang lebih baik

## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Tinjauan Pustaka

Uswatun (2020) telah melakukan penelitian untuk mengetahui pengaruh dari augmentasi data menggunakan model VGG16 dengan metode transfer learning dalam mengklasifikasikan batik, data augmentasi digunakan untuk memperoleh duplikasi variasi gambar dengan melakukan membalik, penambahan noise, translasi, flipping, rotasi, pembesaran, dan transformasi (Hussain et al., 2017), dengan menggunakan 8 augmentasi data pada dataset 500 citra batik yang terdiri atas 5 kelas yaitu Ceplok, Kawung, Lerang, Nitik dan Parang. Dengan menggunakan teknik augmentasi data terjadi proses peningkatan akurasi 3,13% dari 95,83% menjadi 98,96%.

Gultom (2018) dalam penelitian sebelumnya, melakukan klasifikasi pola batik menggunakan CNN dengan arsitektur *Transfer Learning* menggunakan model VGG16 dengan membandingkan akurasi model SIFT dan SURF. Walaupun tidak menghasilkan sebaik model SIFT dan SURF, VGG16 dapat mencapai relatif yang tinggi. Hal ini dapat disimpulkan bahwa ekstraksi fitur menggunakan model *transfer learning* dapat menangani perubahan varian pada motif batik sebaik model SIFT dan SURF. Ekstraktor VGG16 pra-terlatih lebih efisien dari SIFT dan SURF bag of words (BoW) karena tidak memerlukan segala bentuk pemasangan data atau pelatihan dengan dataset Batik. Sementara itu, SIFT / SURF membutuhkan pengelompokan Batik SIFT / SURF deskriptor untuk membangun kosa kata visual.



Selain itu, VGG16 extractor dapat dijalankan secara paralel di GPU untuk lebih lanjut mengurangi eksekusi waktu. VGG16 sebagai fitur ekstraksi mencapai nilai akurasi rata – rata  $89 \pm 7\%$  sedangkan model SIFT dan SURF mencapai rata – rata  $88 \pm 10\%$  dan  $88 \pm 8\%$ .

Artha (2018) melakukan penelitian mengklasifikasi pola batik menggunakan model VGG-16 dan VGG1 yang dilakukan *Augmentation data*, penelitian ini membandingkan akurasi klasifikasi dari model VGG-16 dan VGG-19 dengan gambar yang diputar dan diskalakan. Percobaan dilakukan dengan 3 metode, pertama dilakukan dalam dataset Non-split, kedua percobaan dalam dataset split dan yang terakhir evaluasi keakuratan gambar yang diputar dan diskalakan. Training dan testing akurasi metode VGC-16 dan VGC-19 memiliki celah yang lebar, dengan celah sekitar 0,43. Akurasi training data lebih tinggi dari akurasi testing dan ini mengindikasikan bahwa model terlalu cocok dengan data training. Itu terjadi karena dataset hanya 60 gambar untuk setiap kelas. Jumlah gambar tidak cukup untuk mendapatkan fitur umum. Kinerja klasifikasi tanpa perputaran dan merubah skala gambar menurun pada dataset berskala yang lebih tinggi, model gagal memprediksi kelas gambar dataset, setelah classifier dilatih menggunakan data augmentation tingkat akurasi meningkat hingga 9%. Keakuratan classifier non-augmented hanya berkurang hingga 21%, itu berarti VGC-16 atau VGC-19 dapat lebih menangani data yang diputar daripada data yang diskalakan.

Wicaksono (2017), penelitian ini mengklasifikasi berbagai motif batik menggunakan *Deep learning* dengan metode *Convolutional Neural Network* yang

digabungkan dengan *GoogLeNet* dan *Residual Network*. Dari hasil pengujian akurasi dan waktu proses, Arsitektur IncRes-2 memiliki akurasi yang lebih baik daripada *GoogLeNet* dan *Residual Network*, Arsitektur IncRes-4 memiliki yang tercepat waktu eksekusi 636 ms untuk satu gambar, ini memiliki waktu tercepat eksekusi karena memerlukan lebih sedikit komputasi dari pengurangan jumlah modul IncRes, sedangkan IncRes-2 arsitektur yang memiliki akurasi paling tinggi tidak begitu banyak waktu komputasi yang berbeda pada 733 ms per gambar. Bahwa peningkatan ukuran output dikonvolusi awal dalam IncRes-3 mempengaruhi lebih lama waktu perhitungan, dan juga dengan jumlah yang lebih besar jumlah saluran keluaran pada Inception *GoogLeNet* yang disesuaikan dengan arsitektur IncRes-1 juga menyediakan lebih lama, tetapi kedua arsitektur memiliki akurasi yang lebih rendah dari arsitektur IncRes-2. *GoogLeNet* dan *Residual Jaringan* memiliki waktu eksekusi yang lebih lambat karena keduanya membutuhkan lebih banyak waktu komputasi dengan lebih dari 0.8 detik untuk setiap gambar di *GoogLeNet* dan lebih dari 2.2 detik ke *Residual Network* 50 lapisan yang memang memiliki ukuran jaringan yang lebih besar.

Rochman (2020) melakukan penelitian menggunakan *pretrained model* pada CNN untuk klasifikasi ordo tumbuhan dengan input menggunakan citra daun pada 8 kelas ordo tumbuhan dengan jumlah dataset awalnya masing – masing 200 image dengan menggunakan beberapa arsitektur, untuk model VGG16 dan ResNet50 dengan ukuran data input 224x224 piksel dan model *Inception-v3* menggunakan input ukuran dataset 299x299 piksel. preprocessing dataset dilakukan dengan rotasi dan flip yang memperoleh penambahan dataset pada

masing – masing kelas menjadi 600 citra. 3 Model yang digunakan pada proses *Classification* dilakukan fine tuning. Pengujian pada penelitian dilakukan dengan 40 iterasi dan ukuran batch sebesar 32, dataset untuk proses training menggunakan sebanyak 3360 citra dengan mengambil dari masing – masing kelas 420 citra dan validasi dilakukan dengan 1440 citra dengan masing – masing 180 citra pada tiap kelasnya. Diperoleh dalam penelitian, model ResNet memberikan akurasi pada proses validasi sebesar 87,5% pada iterasi ke 40, model Inception pada iterasi yang sama memberikan akurasi sebesar 88,9% sedangkan model VGG tidak memberikan nilai yang baik pada penelitian dengan akurasi 42% pada iterasi ke 40.

Tammina (2019) dalam penelitian klasifikasi biner untuk binatang anjing dan kucing yang membandingkan hasil accuracy antara model CNN dengan arsitektur VGG16 yang menggunakan fine tune dan augmentasi image. Dataset yang digunakan berisi 2500 data gambar anjing dan kucing yang 5000 data sebagai validasi dan 2000 data gambar sebagai data latih. Augmentasi data gambar yang dilakukan dengan *zoom\_range* memperbesar gambar, memutar, melebarkan, menggeser dan merubah ukuran skala gambar ide untuk mengaugmentasi data gambar agar memperoleh gambar dengan semakin banyak dengan perubahan dan ukuran lain tanpa merusak data data asli. Kedua model tersebut memberikan hasil yang signifikan pada model CNN memberi hasil accuracy 72,40 % tanpa augmentasi, dengan model CNN menggunakan augmentasi memberikan hasil 79,20% dan model arsitektur VGG16 yang menggunakan fine tuned dan augmentasi pada gambarnya memberikan hasil akurasi sebesar 95.40%.

Putra (2021) yang memanfaatkan arsitektur CNN MobileNetV2 dengan pre-trained transfer learning dalam mengklasifikasikan batik tulis dan batik cetak, memberikan akurasi pada training sekitar 96,91%, dan akurasi pada validasi sebesar 94,74%. Saat pengujian dengan data yang belum dikenali model memberikan akurasi 87,5%. Penelitian ini menggunakan 566 image sebagai dataset yang dibagi menjadi 3 bagian yaitu 80% untuk training, 10% untuk validasi dan 10% untuk testing sehingga dari komposisi tersebut diperoleh dataset training adalah 248 batik tulis dan 205 batik cetak, dataset validasi adalah 31 batik tulis dan 26 batik cetak dan dataset pengujian adalah 31 batik tulis dan 25 batik cetak. Dengan dataset yang tidak besar ini untuk mencegah terjadinya overfitting dan menambah variasi data, penelitian ini melakukan augmentasi data secara realtime sehingga tidak mengubah keaslian datanya. Transformasi image yang dilakukan meliputi rotasi, zoom, geser, flip horizontal dan merubah ukuran image dengan memanfaatkan Image Data Generator milik API Keras. Dalam penelitian ini menyimpulkan bahwa augmentasi data menambahkan akurasi jika dengan dataset yang terbatas.

## 2.2. Keaslian Penelitian

Tabel 2. 1 Matriks literatur review dan posisi penelitian  
Klasifikasi Motif Batik Papua Menggunakan Deep Learning

| No | Judul   | Peneliti, Media Publikasi, dan Tahun   | Tujuan Penelitian   | Kesimpulan  | Saran atau Kelemahan   | Perbandingan   |
|----|---|--|---|---|--|--|
| 1  | Batik Classification Using Deep Convolutional Network Transfer Learning | Gultom, Yohanes., Masikome Rian Josua, Arymurthy Aniasi Murni., Journal of a Science and Information, 2018 | Peneliti melakukan klasifikasi pola batik menggunakan membandingkan model VGG16 dengan arsitektur transfer learning dengan model yang berbasis SIFT dan SURF. | Dengan ekstraksi feature transfer learning hasil model VGG16 relatif lebih tinggi dibandingkan model berbasis SIFT dan SURF yang dapat disimpulkan bahwa <i>transfer learning</i> dapat menangani perubahan varian pada motif batik sebaik model SIFT dan SURF. | Motif batik pada dataset sering tumpang tindih satu sama lain dan ditempatkan pada label yang berbeda secara bersamaan, hal ini membingungkan dalam pengklasifikasi selama training dan menyebabkan generalisasi yang kurang akurat. | Pada penelitian ini akan menggunakan arsitektur MobileNetV2 dengan transfer learning dan fine tuning dengan menggunakan feature augmentation dan perubahan skala untuk optimasi dalam klasifikasi batik. |
| 2  | Batik Classification Utilizing Deep Learning                            | Agastya, I Made Artha., Setyanto.  | Melakukan klasifikasi corak batik menggunakan   | Penelitian dilakukan dalam 3 skenario. Pertama dilakukan percobaan dalam  | Diperoleh dalam penelitian ini gagal menggeneralisir   | Pada penelitian ini akan menggunakan arsitektur MobileNetV2 dengan transfer learning dan   |

Tabel 2.1. Matriks literatur review dan posisi penelitian (Lanjutan)

| No | Judul   | Peneliti, Media Publikasi, dan Tahun   | Tujuan Penelitian  | Kesimpulan   | Saran atau Kelemahan   | Perbandingan   |
|----|---|--|--|--|--|--|
|    | Techniques and Data Augmentation  | Arief. ICITISEE, 2018  | VGG-16 dan VGG-19 dengan melakukan rotasi image dan perubahan skala  | dataset Non-split, kedua percobaan dalam dataset split dan yang terakhir evaluasi keakuratan gambar yang diputar dan diskalakan. | model pada dataset non-split dan akurasi yang sangat rendah, hal itu disebabkan karena overfitting dengan data training.   | fine tuning dengan menggunakan feature augmentation dan perubahan skala untuk optimasi dalam klasifikasi batik.  |
| 3  | Implementation of Data Augmentation Convolutional Neural Network for Batik Classification | Chan Uswatun Khasanah, dkk The 8 <sup>th</sup> International Conference on Cyber and IT Service Management (CITSM) on Virtual, October 23 – 24, 2020 | Mengetahui pengaruh implementasi augmentasi data menggunakan model VGG16 dengan tranfer learning dalam mengklasifikasi batik | Akurasi klasifikasi batik menggunakan Model pre-trained VGG16 dapat ditingkatkan dengan menerapkan augmentasi data.              | Penelitian memiliki dataset sebanyak 500 image dalam 5 kelas, untuk memperoleh generalisasi butuh lebih banyak dataset untuk melihat akurasi pengaruh augmentasi | Pada penelitian ini akan menggunakan arsitektur MobileNetV2 dengan transfer learning dan fine tuning dengan menggunakan feature augmentation dan perubahan skala untuk optimasi dalam klasifikasi batik. |
| 4  | Klasifikasi Keaslian Batik  | Farrel Athaillah   | Penelitian ini menggunakan   | arsitektur CNN MobileNetV2   | Penelitian ini menggunakan 566   | Penelitian yang akan dilakukan akan  |

Tabel 2.1. Matriks literatur review dan posisi penelitian (Lanjutan)

| No | Judul  | Peneliti, Media Publikasi, dan Tahun   | Tujuan Penelitian  | Kesimpulan   | Saran atau Kelemahan  | Perbandingan  |
|----|--|--|--|--|---|---|
|    | Menggunakan Algoritma Jaringan Saraf Konvolusi dengan Metode Pembelajaran Transfer | Putra dkk, 2021 Sixth International Conference on Informatics and Computing (ICIC) | arsitektur CNN MobileNetV2 dengan pre-trained transfer learning dan melakukan augmentasi data untuk mengklasifikasi batik tulis dengan batik cetak | dengan pre-trained transfer learning memberikan akurasi pada training sekitar 96,91%, dan akurasi pada validasi sebesar 94,74%. Saat pengujian dengan data yang belum dikenali model memberikan akurasi 87,5%. | image sebagai dataset yang dibagi menjadi 3 bagian yaitu 80% untuk training, 10% untuk validasi dan 10% untuk testing sehingga dari komposisi tersebut diperoleh dataset training adalah 248 batik tulis dan 205 batik cetak, dataset validasi adalah 31 batik tulis dan 26 batik cetak dan dataset pengujian adalah 31 batik tulis dan 25 batik cetak. Dengan dataset yang tidak besar ini untuk mencegah terjadinya overfitting dan menambah variasi data, penelitian ini | membandingkan akurasi dari tiap – tiap augmentasi yang dilakukan. |

Tabel 2.1. Matriks literatur review dan posisi penelitian (Lanjutan)

| No | Judul   | Peneliti, Media Publikasi, dan Tahun                                 | Tujuan Penelitian   | Kesimpulan   | Saran atau Kelemahan   | Perbandingan   |
|----|---|--|---|--|--|--|
|    |   |  |   |  | melakukan augmentasi data secara realtime sehingga tidak mengubah keaslian datanya   |  |
| 5  | Modified Convolutional Neural Network Architecture for Batik Motif Image Classification | Wicaksono, Ardian Yusuh. dkk, Journal of Science, Vol 2, No. 1, 2017 | Penelitian ini mengklasifikasi berbagai motif batik menggunakan Deep learning dengan metode Convolutional Neural Network yang menggabungkan model GoogLeNet dan Residual Network yang dikenal dengan IncRes | Dalam mengklasifikasi citra motif batik dapat menggunakan model IncRes dengan akurasi mencapai 70.84% dengan waktu komputasi 733 ms. | arsitektur akan dirancang lebih efisien untuk menghemat waktu komputasi, dan juga penggunaan pembelajaran transfer atau fine-tuning bobot konvolusi dari dataset lain yang lebih baik dapat diterapkan untuk mendapatkan performa dan ketahanan yang lebih baik. | Pada penelitian ini akan menggunakan arsitektur MobileNetV2 dengan transfer learning dan fine tuning dengan menggunakan feature augmentation dan perubahan skala untuk optimasi dalam klasifikasi batik. |



Tabel 2.1. Matriks literatur review dan posisi penelitian (Lanjutan)

| No | Judul  | Peneliti, Media Publikasi, dan Tahun  | Tujuan Penelitian  | Kesimpulan   | Saran atau Kelemahan   | Perbandingan   |
|----|--|---|--|--|--|--|
| 6  | Transfer Learning With Fine – Tuned MobilenetV2 For Diabetic Retinopathy | Rupa Patel dkk, International Ceonference for Emerging Technology (INCET), Jun 5-7, 2020. | Penelitian ini bermaksud mengklasifikasi image jaringan retina mata untuk menganalisa tingkat keparahan sehingga menyebabkan kebutaan menggunakan pretrained transfer learning dengan model MobilenetV2 yang dikustom pada feature klasifikasi | Transfer learning dalam mengklasifikasi gambar DR dalam 5 kelas dengan menggunakan model pretrained MobileNetV2 sebagai extractor dan menambahkan softmax pada klasifikasi memberikan akurasi 70% dan memberikan akurasi yang lebih tinggi setelah dilakukan fine-tuned. | Pendekatan ini dapat menggunakan training datanya ukuran kecil | Pada penelitian ini akan menggunakan arsitektur MobileNetV2 dengan transfer learning dan fine tuning dengan menggunakan feature augmentation dan perubahan skala untuk optimasi dalam klasifikasi batik. |

## 2.3. Landasan Teori

### 2.3.1 BATIK

UNESO Sejak tanggal 2 Oktober 2009, telah menetapkan Batik Indonesia yang dengan keseluruhan teknologin prses pembuatan serta pengembangan motif dan budaya sebagai Warisan Kemanusiaan untuk Budaya Lisan dan Nonbendawi (Masterpieces of the Oral and Intangible Heritage of Humanity). Batik adalah kain bergambar yang pembuatannya dilakukan secara khusus dengan menuliskan menggunakan malam pada kain itu, selanjutnya dengan proses yang memiliki kekhasan diolah secara tertentu. (Batik, n.d.) . Motif batik Indonesia memiliki banyak jenis, yang membedakan motif pada masing – masing daerah atau ciri khas terdapat pada komponen warna dan pola. Warna dan Pola ini sering tidak terlepas dari filosofi kehidupan yang dihadapi, atau digunakan pada manusia pada daerah tersebut ataukan merupakan warisan lelehur. Selain motif dibedakan per daerah seperti batik ambon, batik papua, batik jawa, batik riau, dan lainnya, perbedaan motif atau pola menjadi rujukan dalam pengklasifikasian batik tersebut.

### 2.3.2 Klasifikasi

Klasifikasi data terdiri dari 2 proses yaitu proses pembelajaran dan tahap klasifikasi, tahap pembelajaran merupakan proses membentuk model klasifikasi, sedangkan tahap pengklasifikasian adalah menggunakan model klasifikasi untuk memprediksi label kelas dari suatu data. Pengklasifikasian atas motif batik saat ini masih mengandalkan pengetahuan dan pengalaman manusia yang memahami motif

batik yang berpotensi salah, dengan algoritma klasifikasi data dapat membantu dalam pengklasifikasian motif batik.

### 2.3.3 Convolution Neural Network

CNN adalah jenis artificial Neural Network (ANN) *feed-forward* dimana masing – masing neuron ditata sedemikian rupa untuk menanggapi daerah *overlapping* pada bidang visual. CNN mengikuti proses biologi dan variasi *perceptrons multilayer* yang dirancang menggunakan *proprocessing* dengan jumlah minimal. Proses biologi yang dimaksud dari karya awal Hubel dan Wiesel pada visual korteks kucing, dimana terdapat susunan sel – sel yang kompleks dalam visual korteks. Sel – sel sensitif terhadap sub-daerah kecil dari suatu ruang masukan disebut *receptive field*, dan tertata sedemikian rupa untuk menutupi keseluruhan bidang visual.

### 2.3.4 Deep Learning

*Deep Learning* merupakan sub bidang dari machine learning yang mengikuti dari cara kerja struktur otak manusia yang dikenal dengan istilah *artificial neural network* untuk memperoleh algoritma yang lebih baik dan mudah digunakan yang dikenal juga sebagai *Deep Neural Network* (DNN) atau *Multi Layer Perceptrons* (MLP). *Deep learning* secara khusus menggunakan neural network dengan jumlah parameter yang lebih besar, dan menjadi salah satu teknik yang populer (Balaban, 2015). *Deep learning* memiliki arsitektur yang bertingkat (*layered*) dengan parameter tertentu, terdapat sebuah *loss function* yang berguna

untuk memetakan sebuah vektor menjadi nilai skalar, memiliki algoritma optimasi sebagai pendukung dari loss function tersebut. Jumlah data pada saat proses training akan sangat berpengaruh pada model yang dihasilkan, semakin banyak jumlah data akan memberikan kualitas model yang lebih baik. Beberapa hal yang mengangkat popularitas *deep learning* digunakan, yaitu tingkat perkembangan kecepatan dalam kemampuan komputasi, biaya perangkat komputasi jauh lebih rendah dan perkembangan dalam algoritma *deep learning* (Deng, 2016).

### 2.3.5 Transfer Learning

*Transfer Learning* merupakan proses peningkatan pembelajar dalam menangani data baru melalui pengetahuan dari tugas terkait yang telah ditraining, diketahui bahwa pernah mentraining klasifikasi sederhana mengenai sebuah objek, maka dari hal tersebut kita bisa mengklasifikasikan objek lain menggunakan pengetahuan yang telah diperoleh dari model tersebut, dalam hal ini yang ditransfer adalah "weight" yang telah dipelajari pada objek sebelumnya untuk melakukan tugas baru. Pemicu proses ini adalah dengan menghasil performa yang baik membutuhkan data yang banyak, sedangkan jumlah data yang tersedia masih berjumlah sedikit atau bahkan belum terlabeli. Sehingga untuk menghemat agar proses tidak dari awal, dengan jumlah data yang tidak banyak dan waktu proses yang lama, maka dapat menggunakan pembelajaran terkait tugas yang pernah dipelajari sebelumnya. Pelatihan bertujuan mengurangi terjadinya *Cross Entrophy*, dimaksudkan sebagai *loss function* yang dapat memberikan gambaran tentang seberapa baik proses pembelajaran berlangsung. Kebutuhan data dan komputasi

yang besar untuk training data akan dimudahkan dengan mengkombinasikan neural network dengan hadirnya *transfer learning*

### 2.3.6 Data Augmentation

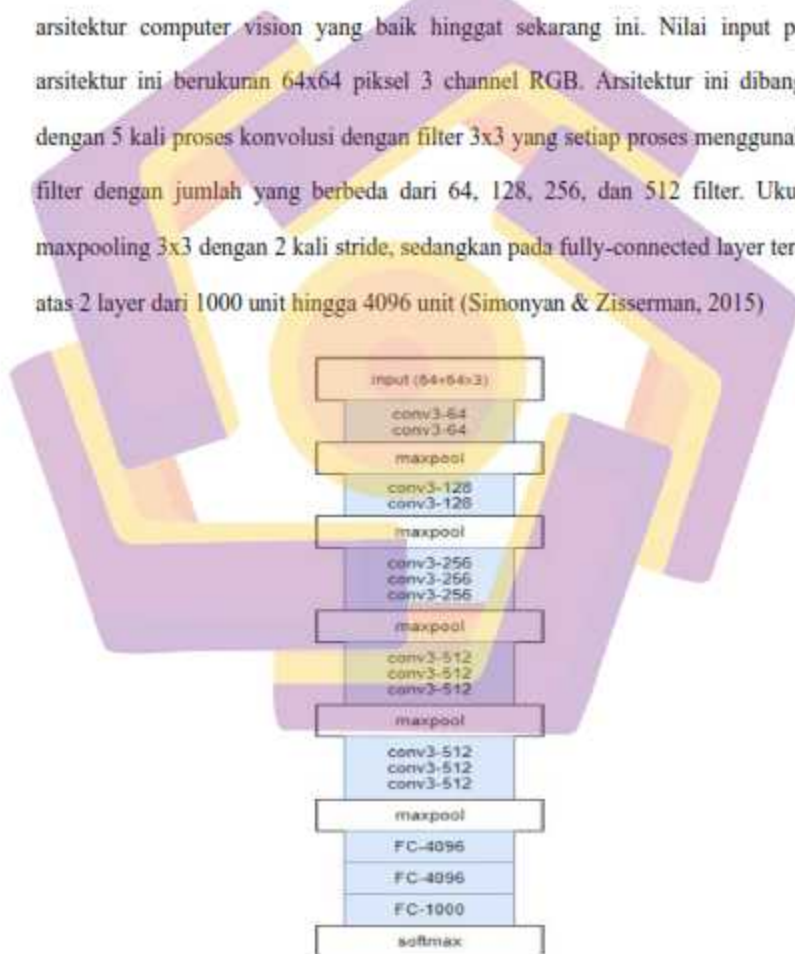
Dibutuhkan dataset dalam jumlah banyak dalam penggunaan deep learning agar dapat memberikan performa yang optimal dengan tersedianya berbagai variasi model yang dikenalkan pada saat training. Hal ini dapat diperoleh dengan melakukan augmentasi data pada dataset dengan melakukan transformasi pada image. Dikenal ada 2 metode augmentasi yaitu *Unsupervised Data Augmentation* yang metode augmentasinya tidak tergantung pada data label seperti berikut ini (Shijie et al., 2017) :

- *Cropping* dilakukan dengan memilih area tertentu pada gambar asli dan merubahnya pada resolusi tertentu.
- *Flipping* dilakukan membalikkan gambar secara vertikal maupun horizontal
- *Rotation* dilakukan dengan memutar gambar dengan nilai derajat secara acak
- *Shifting* dilakukan dengan menggeser gambar ke arah kiri dan kanan dengan jarak gesernya dapat ditentukan
- *Color Jittering* dilakukan dengan merubah faktor saturasi warna, kecerahan dan kontrak gambar secara acak
- *Noise* dilakukan menambahkan noise dengan acak dari setiap piksel gambar
- *PCA (Principal Component Analysis) Jittering* dilakukan dengan menambahkan gambar asli dengan gaussian sebesar  $(0,0,1)$  pada gambar

yang diperoleh dari melakukan PCA pada gambar sehingga menjadi gambar baru

### 2.3.7 Arsitektur VGG16

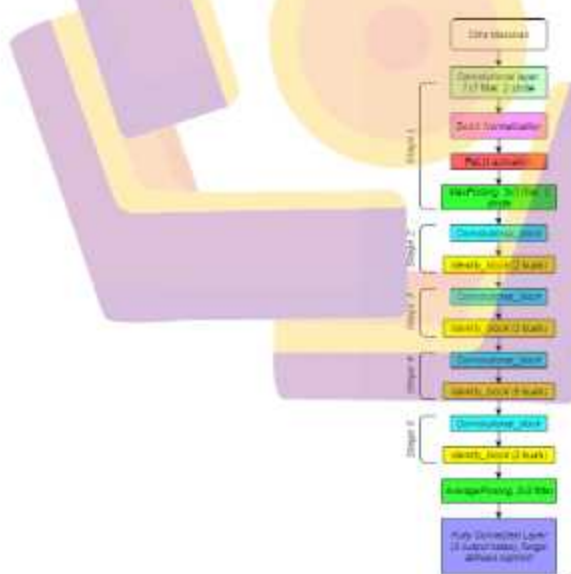
Pada tahun 2014 kompetisi ImageNet Large Scale Visual Recognition Challenge (ILSVRC) dimenangkan oleh VGG16 dan dianggap merupakan arsitektur computer vision yang baik hingga sekarang ini. Nilai input pada arsitektur ini berukuran  $64 \times 64$  piksel 3 channel RGB. Arsitektur ini dibangun dengan 5 kali proses konvolusi dengan filter  $3 \times 3$  yang setiap proses menggunakan filter dengan jumlah yang berbeda dari 64, 128, 256, dan 512 filter. Ukuran maxpooling  $3 \times 3$  dengan 2 kali stride, sedangkan pada fully-connected layer terdiri atas 2 layer dari 1000 unit hingga 4096 unit (Simonyan & Zisserman, 2015)



Gambar 2. 1 Layer VGG16

### 2.3.8 Arsitektur Resnet50

Dalam upaya meningkatkan akurasi sebuah arsitektur dilakukan pendalaman suatu jaringan dengan menumpuk banyak layer. Pendalaman ini dapat mengakibatkan gradient menjadi kecil sehingga mempengaruhi kerja akurasi menurun, hal ini dikenal dengan vanishing gradient problem. Residual Network atau dikenal dengan ResNet50 memperkenalkan shortcut connection yang terkait dengan vanishing gradient problem (He et al., 2016). Konsep shortcut connection bekerja dengan input dari layer sebelumnya menjadi input atas output dari layer tersebut, hal ini dilakukan agar saat proses konvolusi tidak hilangnya fitur – fitur penting. Arsitektur ini terdiri atas 5 stage layer konvolusi yang berikutnya average pooling dan diujungnya ada fully connected layer yang menjadi layer prediksi.



Gambar 2. 2 Diagram Blok Algoritma Resnet50

### 2.3.9 Evaluasi Model

Tahapan berikutnya adalah evaluasi model, dalam hal penelitian ini berhubungan dengan performa dari model yang digunakan dalam mengklasifikasi. Adapun perangkat analisa yang umum digunakan adalah *confusion matrix* yang ditampilkan dalam bentuk tabel yang memberikan nilai pada prediksi dan label dari model klasifikasi. Ilustrasi confusion matrix dapat terlihat pada tabel di bawah ini :

Tabel 2. 2 Confusion Matrix

|            | P <sup>o</sup> (predicted) | N <sup>o</sup> (predicted) |
|------------|----------------------------|----------------------------|
| P (actual) | True Positive (TP)         | False Negative (FN)        |
| N (actual) | False Positive (FP)        | True Negative (TN)         |

Berikut penjelasan dan rumusan masing – masing parameter dimaksud di atas :

- *Accuracy* merupakan perbandingan antara jumlah prediksi yang benar dengan jumlah keseluruhan prediksi benar dan salah, dapat dirumuskan seperti di bawah ini :

$$accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \dots\dots\dots (1)$$

- *Precision* merupakan perbandingan antara prediksi benar pada sebuah label dengan keseluruhan prediksi benar atau salah pada label tersebut. dapat digambarkan dengan rumus :

$$precision = \frac{TP}{(TP + FP)} \dots\dots\dots (2)$$

- *Recall* yang biasa disebut juga *sensitivity* dalam mengukur kinerja model untuk menghindari false negative, atau membandingkan True Positive atas *Actual Positive Recall* dengan rumus :

$$recall = \frac{TP}{(TP + FN)} \dots\dots\dots (3)$$

- *F1-score* merupakan kombinasi rata – rata dari presisi dan recall, dengan rumus sebagai berikut :

$$f1 - score = \frac{2TP}{(2TP + FP + FN)} \dots\dots\dots (4)$$



## **BAB III**

### **METODE PENELITIAN**

#### **3.1. Jenis, Sifat, dan Pendekatan Penelitian**

Penelitian ini merupakan penelitian eksperimental, metode penelitian merupakan merupakan teknik atau cara mengumpulkan dan menganalisa data (Hasibuan A, 2007). Pemilihan metode, penggunaannya dan pengumpulan data yang tepat maka akan membantu dalam jalannya sebuah penelitian. Penelitian eksperimen merupakan *Research that allows fro the causes of behavior to be determined* (Hasibuan A, 2007), dapat digambarkan penelitian yang mencari sebab untuk sebuah akibat yang lain dalam kondisi yang telah ditentukan. Penelitian ini bersifat penelitian deskripti, yang bertujuan menyajikan gambaran lengkap untuk eksplorasi suatu kejadian yang terlihat pada sejumlah variabel berkenaan dengan obyek yang teliti. Pendekatan pada penelitian ini menggunakan metode kuantitatif, yang menggunakan ukuran informasi secara numerik dan menerapkan strategi validasi data dengan membandingkan data tersebut dengan sumber yang relevan.

#### **3.2. Dataset yang digunakan**

Dataset yang digunakan dalam penelitian ini merupakan diperoleh dari beberapa sumber pada internet dan hasil pengambilan foto peneliti pada beberapa took penjualan batik di Kota Sorong, yang diperoleh sekitar 40 - 60 image pada masing – masing kelas, Adapun kelas dalam penelitian ini terdiri atas motif batik Raja Ampat, motif batik Asmat, motif batik Tifa Honai dan motif batik

Cendrawasih dapat dilihat pada Tabel berikut 3.1 dan beberapa contoh motif dapat terlihat pada Gambar 3.1 di bawah ini.

Tabel 3. 1 Tabel data motif batik

| Motif Batik             | Jumlah Data |
|-------------------------|-------------|
| Motif Batik Cendrawasih | 43 gambar   |
| Motif Batik Tifa Honai  | 52 gambar   |
| Motif Batik Asmat       | 59 gambar   |
| Motif Batik Raja Ampat  | 53 gambar   |

#### Motif Batik Cendrawasih



#### Motif Batik Asmat



### Motif Tifa Honai




### Motif Batik Raja Ampat



Gambar 3. 1 Beberapa Contoh Dataset Motif

Motif batik terlihat pada Gambar 3.1 menampilkan motif yang non geometri dan kesamaan motif pada masing – masing kelas cukup beragam sehingga hal ini menjadi tantangan dari penelitian ini.

Pada penelitian ini, dataset tersebut akan dilakukan split 80% untuk data latih, 10% untuk data validasi dan 10% untuk data test. Augmentasi data dilakukan pada data latih yang diharapkan dapat memberikan penambahan data sebagaimana terlihat pada gambar 3.2 di bawah ini.



Gambar 3. 2 Augmentasi Dataset

### 3.3. Metode Transfer Learning

Pembelajaran transfer learning digunakan dengan memanfaatkan layer classification, layer ini dikenal merupakan layer terakhir dari 3 lapisan layer yaitu *layer fully connected*, *softmax* dan *output*. Layer classification pada arsitektur VGG16 menggunakan network Linear, Relu, Dropout, Linear dan LogSoftmax. Layer Classification pada arsitektur Resnet50 menggunakan network Linear, ReLU, Linear, ReLU, Linear dan LogSoftmax

Layer classification diganti dengan layer baru yang disesuaikan dengan tugas dan jumlah kelas yang baru. Awalnya layer classification pada algoritma masing – masing dikonfigurasi dengan jumlah kelas pada training sebelumnya, layer ini pada arsitektur tersebut diproses dan diperoleh informasi nilai loss, label yang diprediksi dan probabilitas kelas. Untuk tugas baru, layer tersebut diubah menjadi layer baru dan menyesuaikan dataset dan jumlah kelas yang baru.

### 3.4. Metode Analisis Data

Penelitian ini membandingkan 2 arsitektur CNN dengan pelatihan menggunakan beberapa teknik augmentasi dan transfer learning untuk memperoleh nilai akurasi yang terbaik. Teknik transfer learning digunakan untuk optimasi layer klasifikasi yang bisa dimodifikasi menyesuaikan dengan kondisi dataset yang digunakan

Tiap model akan dilatih menggunakan 1 teknik augmentasi dan dicatat akurasi training dan validasi terbaik yang diperoleh, dan pengujian modelnya menggunakan confusion matrix dari hasil test. Terdapat 7 teknik augmentasi dan 3 kombinasi teknik augmentasi yang akan digunakan pada tiap pelatihan model yang diharapkan diperoleh akurasi terbaik pada teknik augmentasi tertentu dan memberikan kontribusi pemahaman terbaru atas proses augmentasi data.

Proses training menggunakan early stopping dengan maksimalam epoch sebanyak 100 iterasi yang diharapkan dapat menyelesaikan proses pelatihan jika hasil akurasinya tidak meningkat lagi.

### 3.5. Perbandingan Model dengan Dataset lain

Pada tahap ini, dilakukan perbandingan model yang digunakan dalam penelitian ini dengan melakukan training menggunakan dataset batik motif lain yang sering digunakan pada penelitian – penelitian sebelumnya. Dataset batik motif lain tersebut cenderung berbentuk geometris dengan kesamaan pada masing – masing kelas cukup tinggi.

Adapun dataset batik motif lain yang akan decompile menggunakan model yang digunakan pada penelitian ini adalah Motif Ceplok, Motif Kawung, Motif Parang, Motif Lereng dan Motif Nitik.

### 3.6. Alur Penelitian

Pada sub – sub bab ini akan dijelaskan alur penelitian yang digunakan dalam penelitian ini antara lain :

1. Studi Literatur

Mengetahui penelitian – penelitian sebelumnya yang memiliki kaitan dengan penelitian yang dilakukan, yaitu dengan cara membaca jurnal, makalah, buku terkait klasifikasi bati dan metode deep learning yang akan digunakan.

2. Pengumpulan Data

Proses pengumpulan data merupakan sebuah proses mendapatkan data primer untuk penelitian, data primer dalam penelitian ini yaitu gambar motif batik yang dataset tersebut diperoleh dari penelitian sebelumnya.

Dilakukan split dataset menjadi yaitu training, testing dan validation, dengan prosesntasi pembagian data 80:10:10

3. Penentuan Metode

Tahap ini meliputi perancangan skenario sistem berdasarkan studi literatur dalam pembelajaran dari perangkat lunak yang ada. Pada penelitian ini akan menggunakan 2 arsitektur dengan 8 augmentasi data.

4. Data Preparation

Tahap ini mengolah image yang diperoleh untuk disesuaikan kebutuhan arsitektur CNN yang digunakan padding dan resize image

5. Pretrained Model

Memuat arsitektur VGG16 dan Resnet50 kemudian melakukan freeze layer yang tidak digunakan

6. Fine Tuning

Melakukan fine-tuning pada layer Classification pada kedua arsitektur

7. Pengujian dan evaluasi

Pada tahapan ini akan melakukan model akan ditraining menggunakan masing – masing dan kombinasi atas 8 jenis augmentasi data

8. Rekomendasi

Memberikan dan mengusulkan rekomendasi apa saja yang akan diberikan dari hasil yang diperoleh agar menjadi eksplorasi lebih lanjut terhadap pengklasifikasikan batik .

9. Kesimpulan


Kesimpulan dan saran yang didapatkan dari penelitian yang telah dilakukan

10. Penyusunan Laporan dan analisis

Penyusunan laporan merupakan tahapan akhir untuk hasil dari keseluruhan penelitian. Bagian ini memuat penjelasan secara lengkap dan terinci tentang langkah-langkah yang dilakukan dalam melakukan penelitian dimulai dari perumusan permasalahan hingga pengambilan kesimpulan. Selain itu, langkah penelitian juga perlu ditunjukkan dalam bentuk diagram alir langkah penelitian atau framework secara lengkap dan terinci termasuk di dalamnya tercermin algoritma, rule,

pemodelan-pemodelan, desain dan lain-lain yang terkait dengan aspek perancangan sistem.

Berikut ini merupakan gambar 3.2 alur penelitian yang digambarkan dengan menggunakan diagram



Gambar 3. 3 Alur Penelitian



## BAB IV

### HASIL PENELITIAN DAN PEMBAHASAN

Bab ini membahas pre-processing data, pelatihan data dan pengujian data yang menggunakan arsitektur VGG16 dan Resnet50 melalui fine tuning transfer learning disertai penggunaan beberapa model augmentation

#### 4.1. Pre-processing Data

Pada tahapan ini, dataset terlebih dahulu displit atau dibagi kedalam tiga folder data, yaitu data training, data validate dan kemudian data testing. Berikut adalah Gambar 4.1 Tabel Pembagian Dataset

|   | batik_papua       | train_cnt | val_cnt | test_cnt |
|---|-------------------|-----------|---------|----------|
| 0 | motif asmat       | 52        | 7       | 6        |
| 1 | motif cendrawasih | 33        | 5       | 5        |
| 2 | motif raja ampat  | 42        | 5       | 6        |
| 3 | motif tifa honai  | 42        | 5       | 5        |

Gambar 4.1 Pembagian Dataset

Total Data training adalah 169, total data validate 22, dan total data testing adalah 22. Selanjutnya, dataset mengalami proses *Normalisation data*, *Augmentation data* serta *Image Standardization*. Untuk proses normalization, data diubah kedalam format atau type data yang sama, Lalu untuk proses augmentasi, data gambar di transform atau diubah secara acak menggunakan operasi berikut yaitu *Grayscale*, *Colorjitter*, *RandomInvert*, *Random Resize*, *Random Rotation*, *Random Affin*, *Random Horizontal & Vertical*, *Rotation*, *Resizedrop*, dan *Flip*.

Tabel 4.1 berikut ini menunjukkan nilai dari augmentasi yang akan dimodelkan yaitu :

Tabel 4. 1 Nilai augmentasi data

| Data Augmentasi | Nilai   |
|-----------------|---|
| Affine          | Degrees = 30, 70 translate = 0.1, 0.3 scale = 50% - 75%       |
| Grayscale       | Random  |
| Flip            | Horizontal, Vertikal  |
| Invert          | Random  |
| ColorJitter     | Brightness = 40%, Contrast = 40%, saturation = 40%, Hue = 20% |
| Resize          | Size = 256, scale = 80%                                       |
| Rotation        | 45 derajat  |
| Kombinasi I     | Resize, Rotation, Flip  |
| Kombinasi II    | ColorJitter, Grayscale, Invert                                |
| Kombinasi III   | Kombinasi I dan Kombinasi II                                  |


Kemudian Standardizing Image, yaitu proses mengubah ukuran panjang dan lebar gambar menjadi 224 x 224. Tujuan dilakukannya preprocessing tersebut yaitu untuk meningkatkan jumlah ukuran kumpulan data serta kualitas citra. Sehingga nilai perform akurasi yang dihasilkan pada model menjadi bagus.

#### 4.2. Hasil Pemrosesan Data

Berikut adalah hasil dari pengujian tentang pengaruh adanya operasi augmentasi pada tahapan preprocessing data menggunakan arsitektur transfer learning ResNet50 dan VGG16.

#### 4.2.1 Hasil training dan validasi VGG 16 tanpa Augmentasi

Berikut adalah hasil performa dari model yang dibuat dengan menggunakan arsitektur VGG16 tanpa proses augmentasi pada tahapan pre-processing.




Gambar 4.2 Training on VGG16 tanpa Augmentasi

Dari proses training model, didapatkan nilai akurasi pada training data sebesar 76.33% dan validasi data sebesar 75.76%. Training data memiliki tingkat akurasi yang lebih tinggi bila dibandingkan dengan akurasi pada validasi data. Dan nilai loss pada validasi data lebih tinggi bila dibandingkan dengan nilai loss pada training data. Hal tersebut menunjukkan adanya overfitting pada model yang disebabkan karena kurangnya jumlah dataset yang digunakan pada proses pembelajaran.

#### 4.2.2 Hasil training dan validasi Resnet50 tanpa Augmentasi

Selanjutnya adalah hasil performa dari model yang menggunakan arsitektur ResNet50 tanpa proses augmentasi pada tahapan preprocessing.



Gambar 4. 3 Training on ResNet50 tanpa Augmentasi

Model dengan arsitektur ResNet50 tanpa proses augmentasi menghasilkan performa akurasi training data sebesar 80.47% dan akurasi validasi data sebesar 81.82%. Untuk nilai training loss didapatkan sebesar 71% lebih kecil dibandingkan dengan nilai validasi loss sebesar 76%. Hal tersebut menunjukkan adanya overfitting pada model yang dibuat. Overfitting yang terjadi juga disebabkan karena kurangnya jumlah data yang digunakan dalam proses training.


#### 4.2.3 Hasil training dan testing VGG16 dengan Augmentation

Berikut adalah hasil performa dari model arsitektur VGG16 dengan menambahkan proses augmentasi pada tahapan pre-processing. Masing-masing operasi dari proses augmentasi akan dibandingkan untuk melihat operasi augmentasi terbaik yang dapat menghasilkan model klasifikasi terbaik.

#### 4.2.3.1. Hasil training dan validasi dengan proses augmentasi


##### 4.2.3.1.1. *Random Affine*

Berikut adalah hasil citra yang ditambahkan operasi *Random Affine* pada proses augmentasi.



Gambar 4. 4 Hasil Random Affine


Dengan menambahkan operasi Random Affine pada proses augmentasi, didapatkan nilai akurasi training sebesar 59,76% dan akurasi nilai validasi sebesar 54,55%. Sedangkan nilai training loss sebesar 1,04 dan validasi loss sebesar 1,17. Hasil pengujian performa model dapat dilihat pada gambar 4.5. Penambahan data yang bergeser dengan teknik Affine ini tidak memberikan hasil training lebih baik tanpa augmentasi, hal ini disebabkan noise pada data terlalu tinggi menyebabkan model bekerja sangat buruk terlihat pada akurasi training yang rendah dan loss validasi cukup tinggi.



Gambar 4. 5 Training on VGG16 dengan Random Affine

#### 4.2.3.1.2: Grayscale

Untuk pengujian performa model dengan menambahkan operasi *grayscale* pada proses augmentasi, didapatkan nilai akurasi untuk training data sebesar 84.02% dan validasi data sebesar 78.79%. Sedangkan untuk nilai loss yang dihasilkan dari model yaitu, 0.48 untuk training loss dan 0.65 untuk validasi loss. Berikut Gambar grafik yang dihasilkan dari pengujian performa model menggunakan operasi *grayscale*. Dengan teknik grayscale diperoleh model yang loss validasi masih lebih tinggi daripada nilai loss training, ini menandakan model masih overfitting.



Gambar 4. 6 Training on VGG16 dengan Grayscale


#### 4.2.3.1.3. *Flip*

Operasi flip yang ditambahkan dalam proses augmentasi terdiri atas flip horizontal dan flip vertikal. Hasil image yang ditambahkan operasi flip sebagai berikut



Gambar 4. 7 Hasil Flip

Dari hasil penambahan operasi flip pada proses augmentasi, didapatkan performa model akurasi pada training data sebesar 95.27% dan validasi data sebesar 78.79%. Sedangkan nilai loss yang dihasilkan yaitu 0.15 untuk training data dan 0.68 untuk validasi data. Berikut Gambar grafik yang menggambarkan hasil pengujian model pada training data dan validasi data. Dari hasil training dan validasi, model tampak overfitting karena hasil training yang baik tapi tidak begitu baik dalam validasinya.



Gambar 4. 8 Training on VGG16 dengan flip

#### 4.2.3.1.4. Invert


Berikut hasil gambar ketika ditambahkan operasi invert pada proses augmentasi dalam tahapan pre-processing.



Gambar 4. 9 Hasil Invert

Hasil pengujian performa yang didapatkan dengan menggunakan operasi augmentasi invert dapat dilihat pada Gambar 4.10 di bawah ini.





Gambar 4. 10 Training on VGG16 dengan invert

Berdasarkan Gambar grafik diatas, diketahui bahwa nilai akurasi untuk performa model untuk proses training data sebesar 84,62% dan validasi data sebesar 75,76%. Untuk nilai loss yang dihasilkan, didapatkan nilai loss training sebesar 0.51 dan nilai loss validasi sebesar 0.75. Model bekerja baik pada saat training dan tidak lebih baik pada saat validasi, hal ini masih menunjukkan model overfitting dalam proses training.


#### 4.2.3.1.5. ColorJitter

Operasi *ColorJitter* yang digunakan dalam penelitian menggunakan paramater *brightness* 0.4, *contrast* 0.4, *saturation* 0.4 dan *hue* 0.2. Citra yang dihasilkan menggunakan operasi tersebut dapat dilihat pada Gambar dibawah ini



Gambar 4. 11 Hasil Colorjitter


Untuk hasil pengujian performa model didapatkan nilai akurasi sebesar 82,84% untuk training data dan 78,79% untuk validation data. Sedangkan untuk nilai loss yang diperoleh dari model, didapatkan sebesar 0.45 nilai training loss dan 0.67 untuk validation loss. Pada teknik augmentasi ini, factor variance tinggi menyebabkan model pada training bekerja cukup baik tapi untuk validasinya tidak lebih baik. Berikut Gambar yang menampilkan grafik accuracy dan loss dari proses training model



Gambar 4. 12 Training on VGG16 dengan ColorJitter

#### 4.2.3.1.6. Restze

Hasil pengujian model yang menggunakan operasi Resize pada proses augmentasi dapat dilihat pada Gambar 4.13 Grafik hasil pengujian performa model menggunakan Resize.




Gambar 4. 13 Training on VGG16 dengan resize

Dari gambar grafik diatas, diketahui nilai akurasi untuk training data sebesar 71.01% dan validasi data sebesar 81.82%. Sedangkan untuk nilai loss dari proses training model didapatkan, nilai training loss sebesar 0.66 dan validation loss sebesar 0.79, model terlihat underfitting dengna hasil loss yang masih tinggi.

#### 4.2.3.1.7. Rotation

Dengan menggunakan operasi Rotation pada proses augmentasi didapatkan performa model untuk nilai akurasi pada data training sebesar 77.51% dan data validasi sebesar 78.79%. Sedangkan nilai loss untuk training data sebesar 0.59 dan validation data sebesar 0.76. Berikut Gambar 4.14 grafik yang menampilkan performa tingkat akurasi dan loss saat proses training model.



Gambar 4. 14 Training on VGG16 dengan rotation


#### 4.2.3.2. Hasil training dan testing dengan kombinasi augmentasi

Selain menggunakan masing-masing operasi pada proses augmentasi, peneliti juga mencoba menggabungkan beberapa operasi pada proses augmentasi. Berikut ada tiga kombinasi operasi yang digunakan dalam proses augmentasi. Ketiga kombinasi tersebut kemudian dibandingkan untuk mengetahui operasi augmentasi terbaik dalam menghasilkan performa model terbaik.

##### 4.2.3.2.1. Kombinasi Resize, Rotation dan Flip

Pada model kombinasi pertama, operasi augmentasi yang digabungkan adalah operasi *resize*, *rotation* dan *flip horizontal*, *flip vertical*. Penggabungan operasi augmentasi tersebut menghasilkan performa akurasi untuk training sebesar 68.64% dan validation sebesar 78.79%. Sedangkan nilai loss yang dihasilkan dari model adalah 0.73 untuk training loss dan 0.74 untuk validation loss. Berikut adalah Gambar yang menampilkan grafik performa model menggunakan proses augmentasi gabungan *resize*, *rotation* dan *flip*. Nilai loss pada saat training dan


validasi terlihat tinggi, hal tersebut memberikan kesimpulan bahwa model underfitting.



Gambar 4. 15 Training on VGG16 dengan Kombinasi Augmentasi I

#### 4.2.3.2.2. Kombinasi ColorJitter, Grayscale dan Invert

Untuk model kombinasi kedua, operasi augmentasi yang digabungkan adalah operasi *colorfitter*, *grayscale* dan *invert*. Penggabungan operasi augmentasi tersebut menghasilkan performa akurasi untuk training sebesar 62.13% dan validation sebesar 78.79%. Sedangkan nilai loss yang dihasilkan dari model adalah 0.89 untuk training loss dan 0.67 untuk validation loss. Berikut adalah Gambar yang menampilkan grafik performa model menggunakan proses augmentasi kombinasi operasi *colorfitter*, *grayscale* dan *Invert*. Nilai loss pada saat training dan validasi terlihat tinggi, hal tersebut memberikan kesimpulan bahwa model underfitting.



Gambar 4. 16 Training on VGG16 dengan Kombinasi Augmentasi II


#### 4.2.3.2.3. Penggabungan Kombinasi

Pada penggabungan kombinasi ini, model yang dibuat menggunakan penggabungan operasi augmentasi pada model kombinasi pertama dengan model kombinasi kedua. Jadi, operasi augmentasi yang digunakan dalam model ketiga ini yaitu *resize*, *rotation*, *flip horizontal*, *flip vertical*, *colorjitter*, *grayscale* dan *Invert*. Berikut hasil citra dari penggabungan kombinasi operasi proses augmentasi.



Gambar 4. 17 Hasil Penggabungan Kombinasi I dan II

Untuk hasil performa model, dapat dilihat pada Gambar grafik performa model menggunakan penggabungan augmentasi pada model kombinasi pertama dan model kombinasi kedua.



Gambar 4. 18 Training on VGG16 dengan Penggabungan Kombinasi I dan II

Performa akurasi model yang dihasilkan yaitu sebesar 75.15% pada data training, dan 81.82% pada validation data. Sedangkan untuk nilai loss yang didapatkan yaitu, 0.62 untuk training loss dan 0.68 untuk validation loss. Model dengan hasil validasi lebih baik dari training, tetapi kedua nilai loss masih tinggi menandakan model masih underfitting.


#### 4.2.4. Hasil training dan validasi Resnet50 dengan Augmentation

Selanjutnya, pengujian proses augmentasi dilakukan pada arsitektru ResNet50. Sama dengan pengujian diatas, pengujian ini dilakukan untuk membandingkan model yang dihasilkan dengan menggunakan masing-masing operasi proses augmentasi pada arsitektur ResNet50

#### 4.2.4.1. Hasil training dan validasi dengan masing – masing augmentasi

##### 4.2.4.1.1. Random Affine


Berikut adalah hasil citra yang ditambahkan operasi *Random Affine* pada proses augmentasi dengan parameter degrees (30, 70), translate (0.1, 0.3) dan scale (0.5, 0.75).



Gambar 4. 19 Hasil *RandomAffine*

Penambahan operasi Random Affine pada proses augmentasi menghasilkan nilai akurasi training sebesar 62.72% dan akurasi nilai validasi sebesar 63.64%. Sedangkan nilai training loss sebesar 1.018 dan validasi loss sebesar 1.012. Hasil pengujian performa model dapat dilihat pada gambar Nilai loss yang tinggi pada training dan validasi memberikan kesimpulan model underfitting.






Gambar 4. 20 Training on ResNet50 dengan Random Affine

#### 4.2.4.1.2. Grayscale


Untuk pengujian performa model dengan menambahkan operasi *grayscale* pada proses augmentasi, didapatkan nilai akurasi untuk training data sebesar 78.70% dan validasi data sebesar 81.82%. Sedangkan untuk nilai loss yang dihasilkan dari model yaitu, 0.66 untuk training loss dan 0.65 untuk validasi loss. Berikut Gambar grafik yang dihasilkan dari pengujian performa model menggunakan operasi *grayscale*. Model dengan hasil validasi lebih baik dari training, tetapi kedua nilai loss masih tinggi menandakan model masih underfitting.



Gambar 4. 21 Training on ResNet50 dengan Grayscale


#### 4.2.4.1.3. Flip

Operasi flip yang ditambahkan dalam proses augmentasi terdiri atas flip horizontal dan flip vertikal, seperti pengujian sebelumnya pada arsitektur VGG16. Hasil image yang ditambahkan operasi flip dapat dilihat dibawah ini.



Gambar 4. 22 Hasil *flip*


Dari hasil penambahan operasi flip pada proses augmentasi, didapatkan performa model akurasi pada training data sebesar 75.15% dan validasi data sebesar 81.82%. Sedangkan nilai loss yang dihasilkan yaitu 0.75 untuk training data dan 0.72 untuk validasi data. Berikut Gambar grafik yang menggambarkan hasil pengujian model pada training data dan validasi data.



Gambar 4. 23 Training on RestNet50 dengan flip


#### 4.2.4.1.4. Invert

Berikut hasil gambar ketika ditambahkan operasi invert pada proses augmentasi dalam tahapan pre-processing.



Gambar 4. 24 Hasil *Invert*

Hasil pengujian performa yang didapatkan dengan menggunakan operasi augmentasi invert dapat dilihat pada Gambar di bawah ini.




Gambar 4. 25 Training on RestNet50 dengan *Invert*

Berdasarkan Gambar grafik diatas, diketahui bahwa nilai akurasi untuk performa model untuk proses training data sebesar 76.92% dan validasi data sebesar

75.76%. Untuk nilai loss yang dihasilkan, didapatkan nilai loss training sebesar 0.70 dan nilai loss validasi sebesar 0.72.


#### 4.2.4.1.5. ColorJitter

Operasi *ColorJitter* yang digunakan dalam penelitian menggunakan parameter *brightness* 0.4, *contrast* 0.4, *saturation* 0.4 dan *hue* 0.2. Citra yang dihasilkan menggunakan operasi tersebut dapat dilihat pada Gambar dibawah ini



Gambar 4. 26 Hasil *ColorJitter*


Untuk hasil pengujian performa model didapatkan nilai akurasi sebesar 74.56% untuk training data dan 81.82% untuk validation data. Akurasi pada validation data lebih tinggi dibandingkan dengan akurasi pada data training. Sedangkan untuk nilai loss yang diperoleh dari model, didapatkan sebesar 0.81 nilai training loss dan 0.78 untuk validation loss. Berikut Gambar yang menampilkan grafik accuracy dan loss dari proses training model



Gambar 4. 27 Training on RestNet dengan Colorjitter

#### 4.2.4.1.6. Resize

Hasil pengujian model yang menggunakan operasi Resize pada proses augmentasi dapat dilihat pada Gambar 4.28 Grafik hasil pengujian performa model menggunakan Resize.




Gambar 4. 28 Training on RestNet dengan Resize

Dari gambar grafik diatas, diketahui nilai akurasi untuk training data sebesar 79.29% dan validasi data sebesar 84.85%. Sedangkan untuk nilai loss dari proses training model didapatkan, nilai training loss sebesar 0.74 dan validation loss sebesar 0.74.


#### 4.2.4.1.7. Rotation

Berikut hasil gambar ketika ditambahkan operasi rotation pada proses augmentasi dalam tahapan pre-processing.



Gambar 4. 29 Hasil *rotation*

Dengan menggunakan operasi Rotation pada proses augmentasi didapatkan performa model untuk nilai akurasi pada data training sebesar 70.41% dan data validasi sebesar 81.82%. Sedangkan nilai loss untuk training data sebesar 0.81 dan validation data sebesar 0.80. Berikut Gambar 1 grafik yang menampilkan performa tingkat akurasi dan loss saat proses training model.




Gambar 4. 30 Training on ResNet50 dengan Rotation

#### 4.2.4.2. Hasil training dan validasi dengan kombinasi augmentation

Percobaan kombinasi operasi augmentasi yang dilakukan pada arsitektur VGG16, juga diterapkan pada arsitektur ResNet50. Berikut ada tiga kombinasi operasi yang juga digunakan dalam proses augmentasi pada arsitektur ResNet50. Ketiga kombinasi tersebut kemudian dibandingkan untuk mengetahui operasi augmentasi terbaik dalam menghasilkan performa model terbaik

##### 4.2.4.2.1. Kombinasi Resize, Rotation dan Crop


Berikut adalah hasil gambar ketika ditambahkan operasi *resize*, *rotation* dan *flip* pada proses augmentasi dalam tahapan pre-processing



Gambar 4. 31 Hasil kombinasi Augmentasi I

Pada model kombinasi pertama, operasi augmentasi yang digabungkan adalah operasi *resize*, *rotation* dan *flip horizontal*, *flip vertical*. Penggabungan operasi augmentasi tersebut menghasilkan performa akurasi untuk training sebesar 76.92% dan validation sebesar 81.82%. Untuk nilai loss yang dihasilkan dari model adalah 0.75 untuk training loss dan 0.73 untuk validation loss. Berikut adalah Gambar yang

menampilkan grafik performa model menggunakan proses augmentasi gabungan *resize, rotation dan flip*.



Gambar 4. 32 Training on RestNet50 dengan Kombinasi I

#### 4.2.4.2.2. Kombinasi ColorJitter, Grayscale dan Invert

Hasil gambar ketika ditambahkan operasi colorjitter, grayscale dan invert pada proses augmentasi dapat dilihat pada Gambar dibawah ini.




Gambar 4. 33 Hasil Kombinasi Augmentasi II

Untuk model kombinasi kedua, operasi augmentasi yang digabungkan adalah operasi *colorjitter, grayscale* dan *invert*. Penggabungan operasi augmentasi tersebut menghasilkan performa akurasi untuk training sebesar 71.60% dan




validation sebesar 81.82%. Sedangkan nilai loss yang dihasilkan dari model adalah 0.81 untuk training loss dan 0.77 untuk validation loss. Berikut adalah Gambar yang menampilkan grafik performa model menggunakan proses augmentasi kombinasi operasi *colorjitter*, *grayscale* dan *Invert*.



Gambar 4. 34 Training on RestNet50 dengan Kombinasi II


#### 4.2.4.2.3. Penggabungan Kombinasi

Sama halnya dengan operasi penggabungan kombinasi proses augmentasi yang dilakukan pada arsitektur VGG16. Pada penggabungan kombinasi berikut, operasi augmentasi yang digunakan dalam model ketiga ini yaitu *resize*, *rotation*, *flip horizontal*, *flip vertical*, *colorjitter*, *grayscale* dan *Invert*. Berikut hasil citra dari penggabungan kombinasi operasi proses augmentasi.



Gambar 4. 35 Hasil Penggabungan Kombinasi I dan II

Untuk hasil performa model, dapat dilihat pada Gambar grafik performa model ketiga menggunakan penggabungan augmentasi dari model kombinasi pertama dan model kombinasi kedua.



Gambar 4. 36 Training on VGG16 dengan Penggabungan Kombinasi I dan II

Performa akurasi model yang dihasilkan yaitu sebesar 67.46% pada data training dan 87.88% pada validation data. Sedangkan untuk nilai loss yang didapatkan yaitu, 0.85 untuk training loss dan 0.74 untuk validation loss.

#### 4.3. Perbandingan Kinerja

Berikut adalah Tabel 4.2 yang merupakan perbandingan hasil pengujian performa model tanpa proses augmentasi menggunakan arsitektur VGG16 dan Resnet50

Tabel 4. 2 Pengujian arsitektur tanpa proses augmentasi

| Arsitektur | Akurasi Testing (%) |
|------------|---------------------|
| VGG166     | 63,61               |
| ResNet50   | 77,27               |

Dari Tabel 4.1 bisa dilihat bahwa model terbaik tanpa proses augmentasi dihasilkan oleh arsitektur ResNet50, dengan nilai akurasi belum baik hal ini disebabkan data trainnya yang masih sedikit.

Selanjutnya adalah Tabel 4.3 yang menampilkan perbandingan hasil pengujian performa model dengan menggunakan operasi augmentasi yang berbeda-beda untuk arsitektur VGG16.

Tabel 4.3 Pengujian arsitektur VGG16 menggunakan operasi augmentasi

| Augmentasi  | Akurasi Testing (%) |
|-------------|---------------------|
| Affine      | 57.90               |
| Grayscale   | 73.73               |
| Flip        | 63.64               |
| Invert      | 56.52               |
| ColorJitter | 77.27               |
| Resize      | 86.36               |
| Rotation    | 63.64               |

Berdasarkan Tabel 4.3 dapat dilihat bahwa performa model terbaik yaitu ketika citra ditambahkan operasi Resize pada proses augmentasi. Teknik augmentasi Resize memberikan penambahan data dengan perubahan ukuran gambar data training yang merata sehingga performa kinerja akurasi lebih baik dengan augmentasi pergeseran dan perubahan warna yang menambah varian pola semakin banyak.

Tabel 4. 4 Pengujian arsitektur VGG16 dengan kombinasi atau gabungan operasi augmentasi

| Keterangan           | Augmentasi                     | Akurasi Testing (%) |
|----------------------|--------------------------------|---------------------|
| <b>Kombinasi I</b>   | Resize, Rotation, Flip         | 77.27               |
| <b>Kombinasi II</b>  | Invert, ColorJitter, Grayscale | 72.73               |
| <b>Kombinasi III</b> | Kombinasi I & II               | 81.82               |

Dari Tabel 4.4 dapat dilihat bahwa nilai akurasi pada kombinasi I dan Kombinasi II tidak jauh selisihnya. Nilai terbaik berada pada Kombinasi III yang dihasilkan dari arsitektur VGG16 dengan menggunakan kombinasi operasi augmentasi. Penambahan jumlah data dengan augmentasi data beberapa teknik memberikan hasil akurasi tesing yang baik dibandingkan dengan kombinasi sebelumnya tetapi masih lebih baik hasil akurasi testing pada teknik augmentasi resize.

Kemudian pada Tabel 4.4 dibawah ini, yang merupakan hasil pengujian performa model dengan menggunakan masing-masing operasi untuk proses augmentasi pada arsitektur ResNet50.

Tabel 4. 5 Pengujian arsitektur ResNet50 menggunakan operasi augmentasi

| Augmentasi         | Akurasi Testing (%) |
|--------------------|---------------------|
| <b>Affine</b>      | 61.54               |
| <b>Grayscale</b>   | 72.00               |
| <b>Flip</b>        | 73.91               |
| <b>Invert</b>      | 77.27               |
| <b>ColorJitter</b> | 64.87               |
| <b>Reslze</b>      | 69.57               |
| <b>Rotation</b>    | 73.91               |

Berdasarkan tabel 4.5 dapat dilihat bahwa performa model terbaik yaitu ketika citra ditambahkan operasi invert pada proses augmentasi. Hasilnya berbeda dengan pengujian pada arsitektur VGG16. Dimana model terbaik diperoleh ketika operasi Resize ditambahkan pada proses augmentasi. Arsitektur Resnet50 dengan model yang dibangun lebih baik kinerjanya dengan pembaruan warna secara keseluruhan memberikan performa yang lebih baik.

Tabel 4. 6 Pengujian Arsitektur ResNet50 dengan kombinasi atau gabungan Operasi Augmentasi

| Keterangan    | Augmentasi       | Akurasi Testing (%) |
|---------------|------------------|---------------------|
| Kombinasi I   | Resize           | 86.36               |
|               | Rotation         |                     |
|               | Flip             |                     |
| Kombinasi II  | Invert           | 72.73               |
|               | ColorJitter      |                     |
|               | Grayscale        |                     |
| Kombinasi III | Kombinasi I & II | 79.03               |

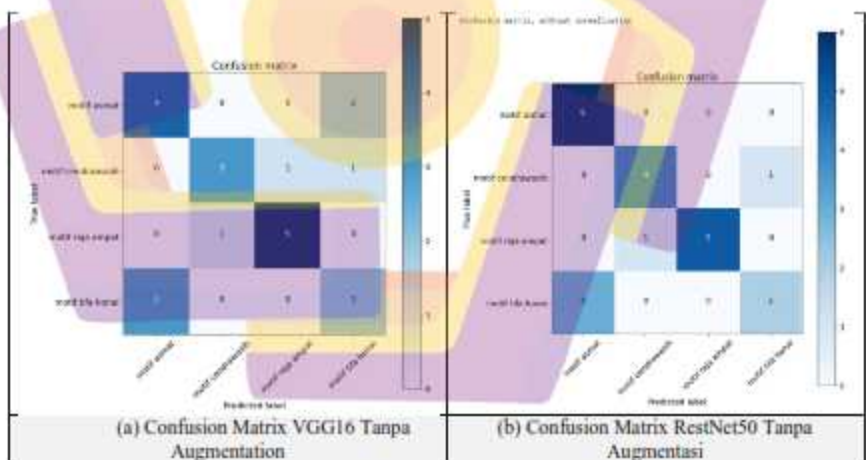
Dari Tabel 4.6 dapat dilihat bahwa performa model terbaik terdapat pada model kombinasi I yang merupakan kombinasi dari teknik Resize, Rotation dan Flip. Penambahan data dengan augmentasi kombinasi III yang lebih banyak tidak memberikan hasil yang lebih baik, disebabkan varian data yang dihasilkan menjadikan pembelajaran menjadi bias yang tinggi. Teknik augmentasi yang tepat dapat memberikan hasil yang lebih baik.

#### 4.4. Evaluasi Model

Setelah model dibuat, kemudian model digunakan untuk melakukan klasifikasi. Performa model dalam melakukan klasifikasi dapat dilihat melalui tabel confusion matriks. Nilai yang tertera pada diagonal utama mewakili gambar yang diklasifikasi dengan benar. Berikut adalah performa prediksi model menggunakan data testing:

##### 4.4.1. Perbandingan Confusion Matrix pada Model VGG16 dan ResNet50 tanpa Augmentasi

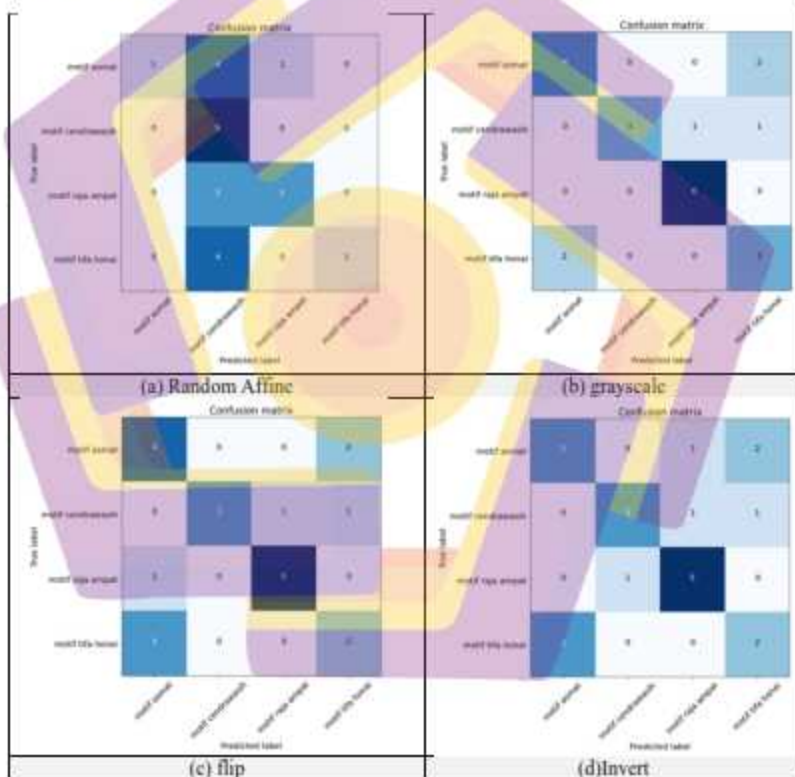
Berikut adalah perbandingan confusion matrix untuk model yang menggunakan arsitektur VGG16 dan ResNet50 tanpa adanya proses augmentasi.

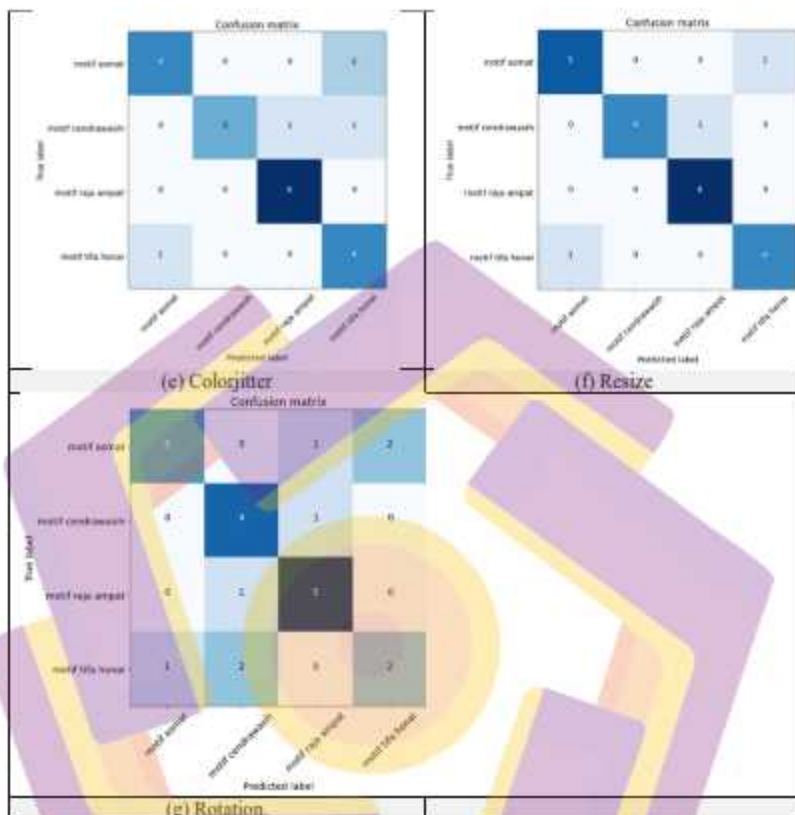


Gambar 4. 37 Confusion Matrix VGG16 dan Resnet Tanpa Augmentation

Dari Gambar 4.37, terlihat bahwa model yang paling banyak mengklasifikasikan gambar dengan benar tanpa menggunakan proses augmentasi adalah Resnet50 sebanyak 17 gambar.

#### 4.4.2. Perbandingan Confusion Matrix pada Model VGG16 dengan Augmentation



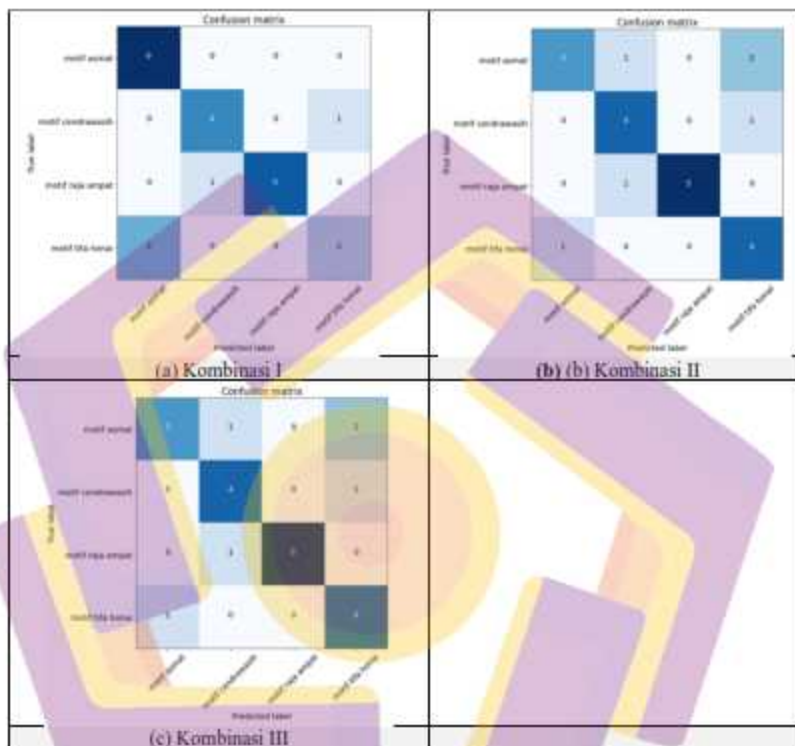


Gambar 4. 38 Confusion Matrix VGG16 dengan Augmentasi

Dari Gambar 4.38, terlihat bahwa model yang paling banyak mengklasifikasi gambar dengan benar adalah model arsitektur VGG16 dengan operasi Resize pada proses augmentasinya. Total jumlah gambar yang dapat diklasifikasi dengan benar sebanyak 19 gambar.




#### 4.4.3. Perbandingan Confusion Matrix pada Model VGG16 dengan Kombinasi Augmentation



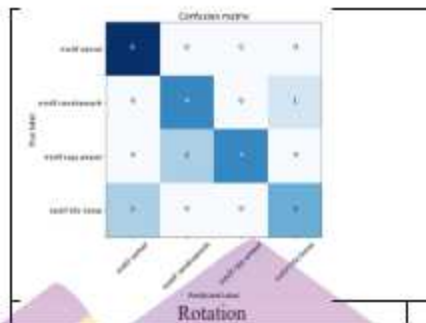
Gambar 4. 39 Confusion Matrix VGG16 dengan kombinasi Augmentasi

Sedangkan pada Gambar 4.39, terlihat bahwa model yang paling banyak mengklasifikasi gambar dengan benar adalah model pada operasi kombinasi I (*resize*, *rotation* dan *flip horizontal*, *flip vertical*). Total jumlah gambar yang dapat diklasifikasi dengan benar sebanyak 17 gambar.

#### 4.4.4. Perbandingan Confusion Matrix pada Model RestNet50 dengan Augmentation



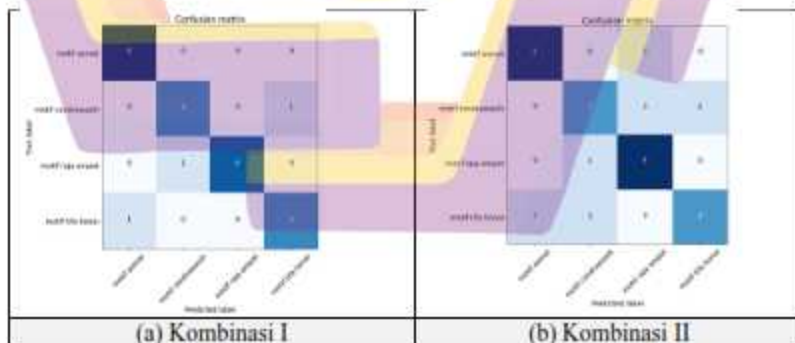
Gambar 4. 40 Confusion Matrix RestNet50 dengan Augmentasi




Gambar 4. 41 Confusion Matrix RestNet50 dengan Augmentasi Rotation

Dari Gambar 4.40 dan Gambar 4.41, terlihat bahwa model yang paling banyak mengklasifikasikan gambar dengan benar adalah model arsitektur RestNet50 dengan operasi Grayscale pada proses augmentasinya. Total jumlah gambar yang dapat diklasifikasikan dengan benar sebanyak 17 gambar.

#### 4.4.5. Perbandingan Confusion Matrix pada Model ResNet50 dengan Kombinasi Augmentasi



Gambar 4. 42 Confusion Matrix RestNet50 dengan Kombinasi I dan Kombinasi II



Gambar 4. 43 Confusion Matrix RestNet50 dengan Kombinasi III

Dari Gambar 4.42 dan Gambar 4.43, dapat kita ketahui bahwa model yang paling banyak mengklasifikasikan gambar dengan benar adalah model arsitektur RestNet50 dengan kombinasi I (*resize, rotation* dan *flip horizontal, flip vertical*). Total jumlah gambar yang dapat diklasifikasikan dengan benar sebanyak 19 gambar.

Dari keseluruhan confusion matrix yang dihasilkan dalam penelitian terlihat bahwa model yang paling banyak mengklasifikasi gambar dengan benar adalah model yang menggunakan arsitektur VGG16 dengan operasi Resize pada proses augmentasinya dan model yang menggunakan arsitektur RestNet dengan operasi kombinasi I (*resize, rotation* dan *flip horizontal, flip vertical*) pada proses augmentasinya. Masing – masing model dapat mengklasifikasikan gambar dengan benar sebanyak 19 gambar.

#### 4.5. Perbandingan Evaluasi Model

Untuk mengevaluasi hasil dari klasifikasi digunakan empat performance matrices, yaitu *accuracy, precision, recall* dan *F1-Score*. Berikut Tabel hasil performance metrics dari masing-masing model yang dibuat dalam penelitian ini.

Tabel 4. 7 Performance Matriks Model VGG16 dan RestNet 50 tanpa Augmentasi

| Arsitektur | Accuracy | Precision | Recall | F1-Score |
|------------|----------|-----------|--------|----------|
| VGG16      | 0.636    | 0.638     | 0.625  | 0.631    |
| ResNet50   | 0.739    | 0.741     | 0.725  | 0.733    |

Tabel 4. 8 Performance Matriks Model VGG16 dengan Augmentasi

| Augmentasi  | Accuracy | Precision | Recall | F1-Score |
|-------------|----------|-----------|--------|----------|
| Affine      | 0.454    | 0.765     | 0.466  | 0.579    |
| Grayscale   | 0.727    | 0.756     | 0.716  | 0.735    |
| Flip        | 0.636    | 0.683     | 0.625  | 0.653    |
| Invert      | 0.590    | 0.591     | 0.583  | 0.587    |
| ColorJitter | 0.772    | 0.807     | 0.766  | 0.78     |
| Resize      | 0.863    | 0.872     | 0.858  | 0.865    |
| Rotation    | 0.636    | 0.633     | 0.633  | 0.633    |

Tabel 4. 9 Performance Matriks Model VGG16 dengan kombinasi augmentasi

| Arsitektur    | Accuracy | Precision | Recall | F1-Score |
|---------------|----------|-----------|--------|----------|
| Kombinasi I   | 0.772    | 0.783     | 0.758  | 0.770    |
| Kombinasi II  | 0.727    | 0.747     | 0.733  | 0.740    |
| Kombinasi III | 0.727    | 0.747     | 0.733  | 0.740    |

Tabel 4. 10 Performance Matriks Model RestNet50 dengan Augmentasi

| Augmentasi  | Accuracy | Precision | Recall | F1-Score |
|-------------|----------|-----------|--------|----------|
| Affine      | 0.727    | 0.754     | 0.725  | 0.739    |
| Grayscale   | 0.818    | 0.825     | 0.808  | 0.816    |
| Flip        | 0.809    | 0.804     | 0.808  | 0.806    |
| Invert      | 0.772    | 0.778     | 0.766  | 0.772    |
| ColorJitter | 0.608    | 0.721     | 0.589  | 0.648    |
| Resize      | 0.695    | 0.693     | 0.689  | 0.691    |
| Rotation    | 0.772    | 0.791     | 0.766  | 0.778    |

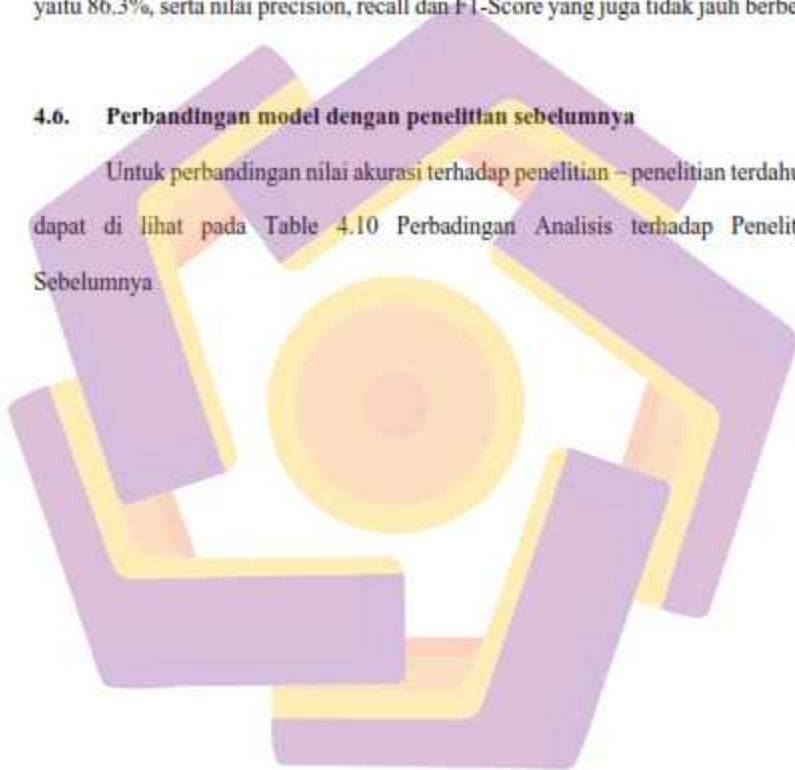
Tabel 4. 11 Performance Matriks Model RestNet50 dengan kombinasi augmentasi

| Arsitektur    | Accuracy | Precision | Recall | F1-Score |
|---------------|----------|-----------|--------|----------|
| Kombinasi I   | 0.863    | 0.864     | 0.858  | 0.861    |
| Kombinasi II  | 0.727    | 0.724     | 0.716  | 0.720    |
| Kombinasi III | 0.772    | 0.815     | 0.766  | 0.790    |

Dari keempat tabel diatas, bisa disimpulkan bahwa performa model klasifikasi yang paling tinggi metric accuracy adalah model VGG16 dengan operasi resize pada proses augmentasinya, dan model RestNet50 dengan operasi kombinasi l pada proses augmentasinya. Keduanya memiliki nilai metrics accuracy yang sama yaitu 86.3%, serta nilai precision, recall dan F1-Score yang juga tidak jauh berbeda.

#### **4.6. Perbandingan model dengan penelitian sebelumnya**

Untuk perbandingan nilai akurasi terhadap penelitian – penelitian terdahulu, dapat di lihat pada Table 4.10 Perbandingan Analisis terhadap Penelitian Sebelumnya.



Tabel 4. 12 Perbandingan Analisis Terhadap Penelitian Sebelumnya

| Penelitian Terdahulu       | Jumlah Dataset dan Class | Algoritma Klasifikasi | Kombinasi Data Augmentasi  | Accuracy % |
|----------------------------|--------------------------|-----------------------|--|------------|
| (Khasanah et al., 2020)    | 500 gambar, 5 kelas      | VGG16                 | Width Shift, Zoom, Rotation, Shear, Height Shift, Random Erasing, Brightness, Channel Shift            | 98.96      |
| (Gultom et al., 2018)      | 2092 gambar, 5 kelas     | VGG16                 | 90 degrees rotation, 180 degrees rotation, 270 degrees rotation, 10% zoom-in, 30% zoom-in, 50% zoom-in | 89.70      |
| (Agastya & Setyanto, 2018) | 900 gambar, 5 kelas      | VGG16                 | Rotated 270 degrees, sheared 0,2 scales, scaled 1,5 scales   | 89.30      |
| (Tumewu et al., 2020)      | 2092 gambar, 7 kelas     | Resnet50              | Rotation, random erase, zoom in, flip Horizontal   | 84.52      |
| Method yang diusulkan      | 213 gambar, 4 kelas      | VGG16                 | Resize   | 86.36      |
| Method yang diusulkan      | 213 gambar, 4 kelas      | Resnet50              | Resize, Rotation, Flip   | 86.36      |

Dari keempat penelitian yang diperbandingkan, model (Khasanah et al., 2020) memiliki nilai akurasi tertinggi sebesar 98.96%. Model yang dibuat menggunakan arsitektur VGG16 dengan operasi pada proses augmentasi yang digunakan adalah Width Shift, Zoom, Rotation, Shear.

#### 4.7. Perbandingan Model dengan Dataset lain

Perbandingan Model dilakukan menggunakan dataset motif batik lain yang sering digunakan pada penelitian terdahulu sesuai pada tabel 4.13 di bawah ini.

Tabel 4. 13 Dataset Motif Batik

| Dataset Motif Batik | Jumlah Gambar |
|---------------------|---------------|
| Motif Ceplok        | 100           |
| Motif Kawung        | 100           |
| Motif Parang        | 100           |
| Motif Mega Mendung  | 100           |
| Motif Nitik         | 100           |

Hasil pengujian dengan model penelitian yang diusulkan diperoleh hasil akurasi pada arsitektur VGG16 dan Resnet50 dengan augmentasi kombinasi Kombinasi III terlihat pada tabel 4.14 di bawah ini.

Tabel 4. 14 Hasil Pengujian

| Arsitektur | Kombinasi Augmentasi data            | Akurasi Training (%) | Akurasi Validasi (%) | Akurasi Testing (%) |
|------------|--------------------------------------|----------------------|----------------------|---------------------|
| VGG16      | Colorjitter, Grayscale, Resize, Flip | 84.21                | 94.21                | 94.12               |
| ResNet50   | Colorjitter, Grayscale, Resize, Flip | 88.25                | 92.00                | 91.89               |

Hasil pelatihan menunjukkan kedua model arsitektur VGG16 dan Resnet50 memberikan hasil yang lebih baik dibandingkan dengan dataset motif dari Papua dalam penelitian ini memperoleh hasil akurasi testing 94.12% untuk VGG16 dan hasil akurasi tesing 91.89% untuk arsitektur Resnet50. Model yang digunakan terlihat memberikan nilai baik pada saat training dan lebih tinggi pada saat testing, dengan hasil tersebut model terlihat bekerja dengan baik untuk mengklasifikasi 5 kelas batik motif tersebut.



Perbedaan keragamana pola pada masing – masing kelas pada kedua dataset tersebut menjadikan model tidak berhasil membentuk pola sehingga nilai akurasi kinerja pada motif batik Papua lebih rendah.

Penemuan dari penelitian berdasarkan hasil diperoleh menggunakan 2 arsitektur, 7 teknik augmentasi dan 3 kombinasi teknik augmentasi adalah :

1. Memberikan kontribusi dataset baru untuk klasifikasi motif batik dari Papua
2. Menggunakan arsitektur Resnet50 dengan teknik resize memberikan hasil akurasi testing 86,36% yang lebih baik dibandingkan dengan penelitian terdahulu.
3. Memperoleh temuan bahwa teknik augmentasi data yang tepat akan memberikan kontribusi dalam meningkatkan peforma kinerja model.
4. Penggunaan transfer learning dapat mengoptimasi hasil kinerja model dengan modifikasi layer klasifikasi yang disesuaikan dengan dataset dan hasil belajar model.

## **BAB V**

### **PENUTUP**

#### **5.1. Kesimpulan**

Dalam penelitian ini dilakukan analisis perbandingan performa arsitektur VGG16 dan ResNet50 serta pengaruh masing-masing operasi pada proses augmentasi kedalam kedua arsitektur tersebut. Operasi pada proses augmentasi yang digunakan pada penelitian ini yaitu, *affine, grayscale, flip, invert, colorjitter, resize, rotation, Kombinasi I (resize, rotation dan flip horizontal, filip vertical), Kombinasi II (colorjitter, grayscale dan invert) dan Kombinasi III (yaitu gabungan antara kombinasi I dan Kombinasi II).*

Hasil penelitian menunjukkan bahwa model yang dibuat dapat melakukan klasifikasi citra motif batik Papua pada arsitektur Resnet50 memberikan akurasi testing 86.36% dengan teknik augmentasi resize dan arsitektur VGG16 memberikan akurasi testing 86.36% dengan teknik augmentasi kombinasi I.

#### **5.2. Saran**

Sebagai saran untuk penelitian berikutnya, yaitu dengan mencoba meningkatkan accuracy dan nilai performance metric model melalui arsitektur transfer lainnya. Selain itu, jumlah dataset yang perlu ditambahkan untuk menghindari proses overfitting pada saat proses training model.

## DAFTAR PUSTAKA

### PUSTAKA BUKU

Goodfellow, I., Bengio, Y., & Courville, A. (2017). *deep learning English version*. 800.

Hasibuan A, Z. (2007). Metode Penelitian Pada Bidang Ilmu Komputer dan Teknologi Informasi. In *Metodologi Penelitian Pada Bidang Ilmu Komputer Dan Teknologi Informasi* (Vol. 4, Issue 1).

### PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

Agastya, I. M. A., & Setyanto, A. (2018). Classification of Indonesian batik using deep learning techniques and data augmentation. *Proceedings - 2018 3rd International Conference on Information Technology, Information Systems and Electrical Engineering, ICITISEE 2018*, 27–31. <https://doi.org/10.1109/ICITISEE.2018.8720990>

Azhari, A. P., & Sulistiyawati, P. (2019). Perancangan Motif Batik Papua Dengan Karakter Burung. *Citrakara*, 01, 1–12.

Balaban, S. (2015). Deep learning and face recognition: the state of the art. *Biometric and Surveillance Technology for Human and Activity Identification XII*, 9457, 94570B. <https://doi.org/10.1117/12.2181526>

*Batik*. (n.d.). Retrieved August 27, 2020, from <https://id.wikipedia.org/wiki/Batik>

Deng, L. (2016). *Deep Learning for AI from Machine Perception to Machine Cognition*.


Eka Putra, W. S. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS*, 5(1).

<https://doi.org/10.12962/j23373539.v5i1.15696>

- Farida, F., & Muhima, R. R. (2018). Image Retrieval Batik Klasik Parang Rusak Menggunakan Ekstraksi Fitur Geometric Invariant Moment, Sobel Dan K-Nn. *Network Engineering Research Operation*, 4(1), 15–21. <https://doi.org/10.21107/nero.v4i1.107>
- Hasibuan A, Z. (2007). Metode Penelitian Pada Bidang Ilmu Komputer dan Teknologi Informasi. In *Metodologi Penelitian Pada Bidang Ilmu Komputer Dan Teknologi Informasi* (Vol. 4, Issue 1).
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *ArXiv*.
- Hussain, Z., Gimenez, F., Yi, D., & Rubin, D. (2017). Differential Data Augmentation Techniques for Medical Imaging Classification Tasks. *AMIA ... Annual Symposium Proceedings. AMIA Symposium, 2017*, 979–984.
- Khasanah, C. U., Utami, E., & Raharjo, S. (2020). Implementation of Data Augmentation Using Convolutional Neural Network for Batik Classification. *2020 8th International Conference on Cyber and IT Service Management, CITSM 2020*, 20–24. <https://doi.org/10.1109/CITSM50537.2020.9268890>
- Lazebnik, S., Schmid, C., & Ponce, J. (2006). Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2, 2169–2178. <https://doi.org/10.1109/CVPR.2006.68>
- Marthen, V., & Mambraku, I. (2014). *Motif Ragam Hias Batik Pada Ruang Publik*.

- Mawan, R. (2020). Klasifikasi motif batik menggunakan Convolutional Neural Network. *Jnanaloka*, 201510370311144, 45–50. <https://doi.org/10.36802/jnanaloka.2020.v1-no1-2>
- Patel, R., & Chaware, A. (2020). Transfer learning with fine-tuned MobileNetV2 for diabetic retinopathy. *2020 International Conference for Emerging Technology, INCET 2020*, 6–9. <https://doi.org/10.1109/INCET49848.2020.9154014>
- Putra, F. A., Jamil, D. A. C., Prabandanu, B. A., Faruq, S., Pradana, F. A., Alya, R. F., Santoso, H. A., Al Zami, F., & Saputra, F. O. (2021). *Classification of Batik Authenticity Using Convolutional Neural Network Algorithm with Transfer Learning Method*. 1–6. <https://doi.org/10.1109/icic54025.2021.9632937>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 4510–4520. <https://doi.org/10.1109/CVPR.2018.00474>
- Shijie, J., Ping, W., Peiyi, J., & Siping, H. (2017). Research on data augmentation for image classification based on convolution neural networks. *Proceedings - 2017 Chinese Automation Congress, CAC 2017, 2017-Janua*(201602118), 4165–4170. <https://doi.org/10.1109/CAC.2017.8243510>
- Wicaksono, A. Y., Suciati, N., Fatichah, C., Uchimura, K., & Koutaki, G. (2017). Modified Convolutional Neural Network Architecture for Batik Motif Image Classification. *IPTEK Journal of Science*, 2(2), 26–30. <https://doi.org/10.12962/j23378530.v2i2.a2846>

Xue, D. X., Zhang, R., Feng, H., & Wang, Y. L. (2016). CNN-SVM for Microvascular Morphological Type Recognition with Data Augmentation. *Journal of Medical and Biological Engineering*, 36(6), 755–764. <https://doi.org/10.1007/s40846-016-0182-4>



## LAMPIRAN

