

**PERBANDINGAN KINERJA ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* (CNN) *LENET* DAN *MOBILENET* PADA IDENTIFIKASI CITRA BATIK LAMPUNG**

**(Skripsi)**

**Oleh**

**HANS CHRISTIAN HERWANTO  
NPM 1917051022**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2023**

**PERBANDINGAN KINERJA ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* (CNN) *LENET* DAN *MOBILENET* PADA IDENTIFIKASI CITRA BATIK LAMPUNG**

**Oleh**

**HANS CHRISTIAN HERWANTO**

**Skripsi**

**Sebagai Salah Satu Syarat untuk Mencapai Gelar  
SARJANA KOMPUTER**

**Pada**

**Jurusan Ilmu Komputer  
Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2023**

## ABSTRAK

### PERBANDINGAN KINERJA ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* (CNN) *LENET* DAN *MOBILENET* PADA IDENTIFIKASI CITRA BATIK LAMPUNG

Oleh

HANS CHRISTIAN HERWANTO

Tujuan dari penelitian ini adalah untuk menilai ketepatan dan efektivitas beberapa arsitektur CNN dalam mengidentifikasi pola-pola rumit yang terlihat dalam berbagai motif Batik Lampung. Sebanyak 500 foto Batik Lampung dikumpulkan, yang terdiri dari sepuluh kategori yang berbeda. Dataset ini kemudian dikenakan prosedur augmentasi, termasuk rotasi, penyesuaian kecerahan, dan teknik zoom. Dataset dibagi menjadi subset yang berbeda, yaitu set pelatihan, set validasi, dan set uji. Desain *LeNet-5* dan *MobileNet* dilatih menggunakan platform mesin Tesla K80, dengan menggunakan *hyperparameter* standar. Hasil evaluasi menunjukkan bahwa *LeNet-5* menunjukkan tingkat akurasi yang lebih tinggi sebesar 99,33% dibandingkan dengan *MobileNet*, yang mencapai tingkat akurasi sebesar 98,00%. Model *LeNet-5* menunjukkan tingkat *precision* dan *recall* yang tinggi, dengan rata-rata masing-masing sebesar 99,40% dan 99,30%. *LeNet-5* telah menunjukkan efektivitas yang lebih tinggi dalam mengidentifikasi motif Batik Lampung meskipun memiliki jumlah parameter yang lebih besar, dengan demikian menunjukkan potensinya untuk pengenalan motif batik lampung. Hasil penelitian ini memberikan kontribusi berharga terhadap penggunaan arsitektur *Convolutional Neural Network* (CNN) untuk tujuan pelestarian dan pengenalan warisan budaya yang beragam di Indonesia, secara khusus, penelitian ini berfokus pada identifikasi motif Batik.

Kata kunci: Batik Lampung, *Convolutional Neural Network*, *LeNet*, *MobileNet*.

## **ABSTRACT**

### **PERFORMANCE COMPARISON BETWEEN LENET AND MOBILENET IN CONVOLUTIONAL NEURAL NETWORK FOR LAMPUNG BATIK IMAGE IDENTIFICATION**

**By**

**HANS CHRISTIAN HERWANTO**

The objective of this research is to assess the accuracy and effectiveness of various CNN architectures in identifying complex patterns observed in various Batik Lampung motifs. A total of 500 Batik Lampung photos were collected, consisting of ten different categories. This dataset underwent augmentation procedures, including rotation, brightness adjustment, and zooming techniques. The dataset was divided into different subsets, namely the training set, validation set, and test set. The LeNet-5 and MobileNet designs were trained using the Tesla K80 machine platform, employing standard hyperparameters. Evaluation results indicate that LeNet-5 demonstrated a higher accuracy rate of 99.33% compared to MobileNet, which achieved an accuracy rate of 98.00%. The LeNet-5 model exhibited high precision and recall rates, averaging 99.40% and 99.30%, respectively. Despite having a larger number of parameters, LeNet-5 has shown higher effectiveness in identifying Batik Lampung motifs, thus indicating its potential for recognizing these patterns. The findings of this research contribute significantly to the use of Convolutional Neural Network (CNN) architectures for the preservation and recognition of diverse cultural heritage in Indonesia. Specifically, this study focuses on the identification of Batik motifs.

Keywords: Lampung batik, Convolutional Neural Network, LeNet, MobileNet.

Judul Skripsi : **PERBANDINGAN KINERJA  
ARSITEKTUR *CONVOLUTIONAL  
NEURAL NETWORK (CNN) LENET* DAN  
*MOBILENET* PADA IDENTIFIKASI  
CITRA BATIK LAMPUNG**

Nama Mahasiswa : Hans Christian Herwanto

Nomor Pokok Mahasiswa : 1917051022

Program Studi : S1 Ilmu Komputer

Jurusan : Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam

**MENYETUJUI**

1. Komisi Pembimbing

  
**Rico Andrian, S.Si., M.Kom**  
NIP. 19750627 200501 1 001

  
**Rahman Taufik, S.Pd., M.Kom**  
NIP. 19930627 202203 1 007

2. Ketua Jurusan Ilmu Komputer

  
**Didik Kurniawan, S.Si., M.T**  
NIP. 19800419 200501 1 004

**MENGESAHKAN**

**1. Tim Penguji**

**Ketua Penguji** : Rico Andrian, S.Si., M.Kom

**Sekretaris Penguji** : Rahman Taufik, S.Pd., M.Kom

**Penguji Utama** : Didik Kurniawan, S.Si., M.T



**2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam**



**Dr. Eng. Heri Satria, S.Si., M.Si.**

**NIP. 197110012005011002**

**Tanggal Lulus Ujian Skripsi: 23 Oktober 2023**

## PERNYATAAN

Saya yang bertanda tangan di bawah ini:

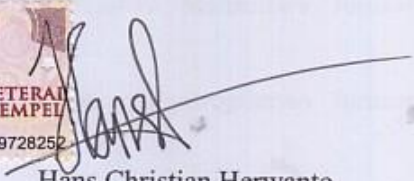
Nama : Hans Christian Herwanto

NPM : 1917051022

Dengan ini menyatakan bahwa skripsi saya yang berjudul "**Perbandingan Kinerja Arsitektur *Convolutional Neural Network (CNN) LeNet dan MobileNet Pada Identifikasi Citra Batik Lampung***" merupakan karya saya sendiri, bukan karya orang lain. Semua tulisan yang tertulis dalam skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Jika dikemudian hari terbukti bahwa karya tulis ilmiah saya terbukti hasil menjiplak karya orang lain, maka saya siap menerima sanksi berupa pencabutan gelar yang saya peroleh.

Bandar Lampung, 23 Oktober 2023



  
Hans Christian Herwanto  
NPM. 1917051022

## RIWAYAT HIDUP



Lahir pada hari Minggu, 25 Maret 2001, sebagai anak kedua dari dua bersaudara, menyelesaikan pendidikan pada tahun 2013 di SD Immanuel Bandar Lampung. Kemudian menyelesaikan pendidikan menengah pertama di SMP Immanuel Bandar Lampung pada tahun 2016. Selanjutnya menyelesaikan pendidikan menengah atas di SMA Immanuel Bandar Lampung pada tahun 2019.

Pada tahun 2019, terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur SNMPTN. Kegiatan yang dilakukan selama menjadi mahasiswa antara lain:

1. Menjadi anggota Adapter Himpunan Mahasiswa Jurusan Ilmu Komputer pada periode 2019/2020.
2. Menjadi anggota Biro Kesekretariatan Himpunan Mahasiswa Jurusan Ilmu Komputer periode 2019/2020.
3. Menjadi kepala Badan Khusus Himpunan Mahasiswa Jurusan Ilmu Komputer periode 2020/2021.
4. Menjadi Asisten Dosen Dasar – Dasar Pemrograman Jurusan Ilmu Komputer pada periode 2020/2021.
5. Menjadi Asisten Dosen Sistem Operasi Jurusan Ilmu Komputer pada periode 2020/2021.
6. Menjadi Asisten Dosen Pemrograman Berorientasi Objek Jurusan Ilmu Komputer pada periode 2021/2022.
7. Menjadi Asisten Dosen Pemrograman Web Jurusan Ilmu Komputer pada periode 2021/2022.



8. Menjadi pemateri Pelatihan Asisten Dosen Jurusan Ilmu Komputer pada periode 2021/2022.
9. Mengikuti ujian sertifikasi dan mendapat sertifikat *Junior Web Developer* oleh Lembaga Sertifikasi Profesi Informatika pada tahun 2022.
10. Menjadi Asisten Dosen Pemrograman Mobile Lanjut Jurusan Ilmu Komputer pada periode 2022/2023.
11. Melaksanakan Kerja Praktik pada bulan Juli 2022 di Kantor Wilayah Kementerian Agama Provinsi Lampung.

## **MOTTO**

*“Life is like the sky that is always moving and changing.”*

**(Tanjirou Kamado)**

*“Do not dwell on past mistakes. No matter how much we cry, we cannot bring them back”*

**(Agatha Christie)**

*“Many failures occur in life, and they are unaware of how close they are to success if they choose not to give up”*

**(Thomas Alva Edison)**

## **PERSEMBAHAN**

Puji dan syukur kepada Tuhan Yang Maha Esa atas segala berkat dan karunia-Nya sehingga dapat menyelesaikan skripsi ini dengan sebaik-baiknya. Berkat kasih kepada umat-Nya seluruh proses dapat diselesaikan dengan sebaik-baiknya. Dengan segala kerendahan dan ketulusan hati saya, saya persembahkan karya akhir ini kepada:

### **Kedua Orang Tua yang saya kasihi**

Yang selalu mendukung dan membawa nama saya ke dalam setiap doa mereka, yang selalu memberikan kasih sayang yang amat besar bagi saya, yang selalu sabar dalam membimbing saya, serta yang telah mengorbankan seluruh jiwa dan raga mereka demi kebahagiaan putra dan putri mereka, saya ucapkan terimakasih sebesar-besarnya atas kasih sayang, didikan dan pengorbanan yang telah diberikan kepada saya dan tak akan mungkin bisa terbalaskan.

### **Untuk Kakak yang paling saya kasihi, Cynthia Octaria**

Yang selama ini memberikan motivasi, dukungan dan arahan yang tidak akan pernah saya lupakan.

Serta

### **Untuk Seluruh Keluarga Besar Ilmu Komputer 2019**

## SANWACANA

Puji Syukur ke hadirat Tuhan Yang Maha Esa, atas berkat dan karunia-Nya, penulis dapat menyelesaikan skripsi yang berjudul “**Perbandingan Kinerja Arsitektur *Convolutional Neural Network (CNN) LeNet dan MobileNet Pada Identifikasi Citra Batik Lampung***”. Dalam melaksanakan penelitian dan penyusunan skripsi ini, penulis banyak mendapat bimbingan dan dukungan dari berbagai pihak, sehingga pada kesempatan ini penulis ingin menyampaikan ungkapan terima kasih yang sebesar-besarnya kepada:

1. Kedua orang tua, Bapak Herwanto dan Ibu Stephanie Stella, yang tidak pernah berhenti memberi dukungan dan motivasi kepada penulis untuk menyelesaikan skripsi dengan baik.
2. Kakak terkasih, Cynthia Octaria, S.Kom., yang selalu memberikan semangat dan motivasi bagi penulis.
3. Bapak Rico Andrian, S.Si., M.Kom., selaku Dosen Pembimbing Utama yang telah memberikan ide dan masukan, serta dukungan kepada penulis selama pembuatan skripsi ini.
4. Bapak Rahman Taufik, S.Pd., M.Kom., selaku Dosen Pembimbing Pembantu yang telah memberikan arahan serta masukan dalam proses pembuatan skripsi ini.
5. Bapak Didik Kurniawan, S.Si., M.T., selaku Ketua Jurusan Ilmu Komputer Universitas Lampung, sekaligus Dosen Pembahas yang telah memberikan kritik dan saran serta motivasi dalam penelitian skripsi ini.
6. Bapak dan Ibu seluruh Dosen dan Staf Jurusan Ilmu Komputer Universitas Lampung yang telah memberikan ilmu serta pengalaman semasa perkuliahan dan membantu selama penelitian.
7. Teman-teman Jurusan Ilmu Komputer Universitas Lampung angkatan

8. 2019 yang telah memberikan dukungan dan telah berjuang bersama menjalankan studi perkuliahan.
9. Abbie Syeh Nahri selaku rekan skripsi yang saling bantu-membantu dalam proses pengerjaan skripsi.
10. Raymond Faraz Yandika, Faishal Hariz Makaarim Gandadipoera, Muhammad Irfun Ardiansyah, Achmad Romadoni, Imam Akbar, Anisa Nadila Lase, Aprila Dwi Utami, Anggie Tamara, Dota Ningtias selaku rekan seperjuangan yang telah memberikan dukungan dan telah berjuang bersama di bangku perkuliahan.

Bandar Lampung, 23 Oktober 2023

Hans Christian Herwanto  
NPM. 1917051022

## DAFTAR ISI

	Halaman
<b>DAFTAR ISI</b> .....	iv
<b>DAFTAR TABEL</b> .....	vi
<b>DAFTAR GAMBAR</b> .....	vii
<b>I. PENDAHULUAN</b> .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Penelitian.....	5
1.5 Manfaat Penelitian.....	6
<b>II. TINJAUAN PUSTAKA</b> .....	7
2.1 Batik .....	7
2.2 <i>Supervised Learning</i> dan <i>Unsupervised Learning</i> .....	13
2.3 <i>Convolutional Neural Network</i> .....	13
2.4 <i>LeNet</i> .....	16
2.5 <i>MobileNet</i> .....	17
2.6 Augmentasi Data .....	18
2.7 <i>Hyperparameter</i> .....	20
2.8 <i>Overfitting</i> .....	22
2.9 <i>Confusion Matrix</i> .....	22
<b>III. METODOLOGI PENELITIAN</b> .....	25
3.1 Waktu dan Tempat .....	25
3.2 Alat dan Bahan .....	26
3.3 Metode.....	27
<b>IV. HASIL DAN PEMBAHASAN</b> .....	31

4.1	Pengumpulan dan Pelabelan <i>Dataset</i> .....	31
4.2	Augmentasi Data .....	32
4.3	Pembagian Data.....	33
4.4	Tahapan Klasifikasi <i>Convolutional Neural Network (CNN)</i> .....	33
4.5	<i>Testing</i> Arsitektur <i>LeNet-5</i> dan <i>MobileNet</i> .....	46
4.6	Pembahasan .....	48
<b>V.</b>	<b>SIMPULAN DAN SARAN</b> .....	<b>57</b>
5.1	Simpulan.....	57
5.2	Saran.....	57
	<b>DAFTAR PUSTAKA</b> .....	<b>59</b>

## DAFTAR TABEL

	Halaman
Tabel 1. <i>Confusion Matrix</i> (Maxwell <i>et al.</i> , 2021) .....	23
Tabel 2. Rencana Penelitian.....	25
Tabel 3. <i>Hyperparameter</i> .....	30
Tabel 4. <i>Dataset</i> Batik Lampung .....	31
Tabel 5. Augmentasi <i>Dataset</i> Batik Lampung.....	32
Tabel 6. <i>Summary</i> struktur hasil <i>output</i> arsitektur <i>LeNet-5</i> .....	39
Tabel 7. <i>Summary</i> struktur hasil <i>output</i> arsitektur <i>MobileNet</i> .....	42
Tabel 8. Hasil akurasi data test arsitektur <i>LeNet-5</i> dengan mesin Tesla.....	46
Tabel 9. Hasil akurasi data test arsitektur <i>MobileNet</i> dengan mesin Tesla.....	47
Tabel 10. Perbandingan kinerja arsitektur <i>LeNet-5</i> dan <i>MobileNet</i> .....	48
Tabel 11. <i>Precision, recall, f1-score</i> arsitektur <i>LeNet-5</i> dengan mesin Tesla.....	51
Tabel 12. <i>Precision, recall, f1-score</i> arsitektur <i>MobileNet</i> dengan mesin Tesla..	54



## DAFTAR GAMBAR

	Halaman
Gambar 1. Batik Lampung (Sembagi).....	7
Gambar 2. Batik Sembagi.....	8
Gambar 3. Batik Granitan.....	8
Gambar 4. Batik Jung Agung.....	9
Gambar 5. Batik Kembang Cengkih.....	9
Gambar 6. Batik Kambil Sicukil.....	10
Gambar 7. Batik Siger Ratu Agung.....	10
Gambar 8. Batik Abstrak.....	11
Gambar 9. Batik Sekar Jagat.....	11
Gambar 10. Batik Sinaran.....	12
Gambar 11. Batik Tambal.....	12
Gambar 12. Model CNN (Alzubaidi <i>et al.</i> , 2021).....	14
Gambar 13. Arsitektur <i>LeNet-5</i> (Mustamin <i>et al.</i> , 2021).....	16
Gambar 14. Arsitektur <i>MobileNet</i> (Wang <i>et al.</i> , 2020).....	17
Gambar 15. Augmentasi <i>Rotation</i> (Lee, 2022).....	19
Gambar 16. Augmentasi <i>Brightness</i> (Lee, 2022).....	20
Gambar 17. Augmentasi <i>Zoom</i> (Lee, 2022).....	20
Gambar 18. Alur Penelitian.....	27
Gambar 19. <i>Source Code</i> Augmentasi Data.....	33
Gambar 21. <i>RGB Image</i> Batik Sembagi.....	35
Gambar 22. Proses konvolusi.....	36
Gambar 23. Proses <i>Pooling</i> .....	37
Gambar 24. <i>Fully-connected Layer</i> .....	37
Gambar 25. Arsitektur <i>LeNet-5</i> .....	38

Gambar 26. <i>Source code</i> arsitektur <i>LeNet-5</i> . .....	40
Gambar 27. Arsitektur <i>MobileNet</i> . .....	40
Gambar 28. <i>Source code</i> arsitektur <i>MobileNet</i> . .....	45
Gambar 29. Grafik perbandingan tingkat akurasi arsitektur <i>LeNet-5</i> menggunakan mesin Tesla K80. ....	46
Gambar 30. Grafik perbandingan tingkat akurasi arsitektur <i>MobileNet</i> menggunakan mesin Tesla K80. ....	47
Gambar 31. <i>Source code running model</i> . .....	48
Gambar 32. Tabel <i>confusion matrix</i> arsitektur <i>LeNet-5</i> dengan augmentasi data. ....	50
Gambar 33. Kesalahan prediksi model <i>LeNet-5</i> . ....	52
Gambar 34. Kemiripan (a) Batik Sekar Jagat dan (b) Batik Jung Agung. ....	52
Gambar 35. Tabel <i>confusion matrix</i> arsitektur <i>MobileNet</i> dengan augmentasi data. ....	53
Gambar 36. Kesalahan prediksi model <i>MobileNet</i> . ....	55
Gambar 37. Kemiripan (a) Batik Sinaran dan (b) Batik Abstrak. ....	55
Gambar 38. Kemiripan (a) Batik Abstrak dan (b) Batik Jung Agung. ....	56

## I. PENDAHULUAN

### 1.1 Latar Belakang

Indonesia memiliki kekayaan budaya yang sangat beragam jenisnya, salah satu jenisnya yaitu batik. Batik memiliki banyak motif dan motif tersebut mencerminkan ciri khas budaya dari tiap daerah. Ragam dari motif batik yang telah ada saat ini contohnya yaitu, Batik Tujuh Rupa di Pekalongan, Batik Sogan di Solo, Batik Gentongan di Madura, Batik Parang di Jawa, Batik Lampung dan yang lainnya. Keberagaman batik tidak hanya dikenal di Indonesia, namun batik juga telah dikenal dan diakui oleh bangsa dan negara lain sebagai bentuk dari kebudayaan Indonesia. Motif batik yang telah ada saat ini tidak lepas dari gaya kehidupan sehari-hari. Batik dikenal sebagai pakaian yang hanya bisa digunakan untuk menghadiri acara formal sebelumnya, sedangkan saat ini batik dapat digunakan untuk pakaian sehari-hari. Batik dari setiap daerah memiliki keunikan tersendiri. Keunikan batik tersebut dapat dilihat dari jenis, pola, warna dan motif.

Batik di Indonesia telah disebutkan sebelumnya memiliki banyak ragam dan jenis, salah satunya yaitu Batik Lampung. Batik Lampung merupakan budaya yang khas dengan motifnya dan menjadi salah satu kegiatan ekonomi yang kuat di Provinsi Lampung (Rusitati *et al.*, 2019). Makna dan filosofi Batik Lampung tidak seperti batik pada umumnya, melainkan lebih mengarah pada kekayaan motif batik yang menunjukkan identitas Lampung itu sendiri. Ragam Batik Lampung bila ditinjau dari proses pembuatannya, terdapat 3 jenis batik yaitu batik tulis, batik cap, dan batik tulis dengan motif Lampung.

Proses pengidentifikasian citra Batik Lampung dibutuhkan agar orang awam dapat mengetahui informasi tentang jenis batik lampung, seperti batik siger kembang cengkih, batik jung agung, batik sembagi and batik siger ratu agung dengan mudah, oleh karena itu, dibutuhkan teknologi yang memudahkan peneliti untuk mengidentifikasi citra batik lampung dengan ciri-ciri dan pola yang terdapat pada batik (Andrian, Naufal, *et al.*, 2019). Teknologi pada saat ini sudah canggih, beberapa diantaranya dapat digunakan untuk mengidentifikasi objek. Teknologi *computer vision* pada *deep learning* atau yang dikenali sebagai *Convolutional Neural Network* (CNN) dapat dimanfaatkan sebagai sarana teknologi untuk proses mengidentifikasi citra pada batik.

*Convolutional Neural Network* (CNN) adalah variasi dari metode *deep learning* yang digunakan sebagai metode yang diusulkan untuk memecahkan masalah klasifikasi batik. CNN merupakan jenis arsitektur jaringan saraf yang digunakan untuk tugas pengenalan pola pada *data visual* seperti gambar dan video. CNN pertama kali diperkenalkan pada tahun 1980-an oleh Yann LeCun, namun pada saat itu teknologi belum cukup maju untuk menghasilkan performa yang memadai (Suartika E. P, I Wayan dan Wijaya Arya Yudhi, 2016). CNN dikenal untuk memecahkan masalah yang berkaitan dengan pengolahan citra. CNN memiliki kemampuan untuk mendeteksi dan mengenali objek dalam sebuah gambar, juga bisa mengungguli metode tradisional dalam visi komputer dan tugas pengenalan pola, seperti deteksi objek, klasifikasi, *image segmentation*, dan *text recognition*. CNN juga dapat secara otomatis mendeteksi pola dalam gambar, tanpa perlu memutuskan pola apa yang diambil dari gambar (Khasanah *et al.*, 2020).

*LeNet* atau *LeNet-5* adalah salah satu arsitektur *convolutional neural network* pertama yang dikembangkan untuk memproses gambar. *LeNet* pertama kali diperkenalkan pada tahun 1998 oleh Yann LeCun, Léon Bottou, Yoshua Bengio, dan Patrick Haffner. Arsitektur *LeNet-5* dikembangkan untuk memproses gambar *handwritten digit* pada dataset MNIST (Mustamin *et al.*, 2021). Arsitektur *LeNet* terdiri dari *convolution layer* dan *sub-sampling*, diikuti oleh *fully-connected layer*.

*LeNet-5* mencakup enam layer, yaitu tiga *convolutional layer*, dua *pooling layer*, dan satu *fully-connected layer* (Wei *et al.*, 2019).

*MobileNet* adalah *Convolutional Neural Network* (CNN) yang dirancang khusus untuk perangkat seluler dan aplikasi mesin pandang komputer (*computer vision*) yang memerlukan pemrosesan cepat dan efisien pada perangkat dengan sumber daya terbatas seperti *smartphone*, tablet, dan perangkat IoT (Nufus *et al.*, 2021). Pengembangan *MobileNet* dimotivasi oleh kebutuhan untuk membuat model CNN yang lebih kecil dan lebih cepat daripada model yang ada saat itu seperti VGG, ResNet, dan *Inception*. *MobileNet* menggunakan teknik yang disebut *separable convolution* untuk mengurangi jumlah parameter model. *Separable convolution* memecah konvolusi menjadi dua tahap, pertama, *spatial convolution* untuk mengambil fitur, dan kedua, konvolusi kedalaman (*depthwise convolution*) untuk menggabungkan fitur-fitur tersebut. Teknik ini menghasilkan model yang lebih ringan dan memerlukan waktu inferensi yang lebih singkat (Haksoro dan Setiawan, 2021).

Penelitian sebelumnya terkait penggunaan arsitektur *LeNet-5* yang dipakai untuk pengenalan doodle dengan arsitektur *LeNet-5*. Penelitian ini dilakukan dengan memanfaatkan CNN dengan menggunakan arsitektur *LeNet-5* untuk mengenali jenis doodle yang terdiri dari lima objek gambar, yaitu baju, celana, kursi, kupu-kupu, dan sepeda. Dataset terdiri dari 150 gambar, dengan setiap objek doodle memiliki 30 gambar. Skenario pertama, kedua, dan keempat mampu mengenali objek sepeda dengan akurasi 93% - 98%, recall 86% - 93%, dan precision 81% - 93%. Sedangkan untuk objek baju, skenario ketiga mampu mengenali dengan akurasi 94%, recall 86%, dan precision 83% (Alwanda *et al.*, 2020).

Penelitian sebelumnya terkait penggunaan arsitektur *MobileNet* yang digunakan untuk pengenalan jenis kayu menggunakan arsitektur VGG16 dan *MobileNet*. Metode CNN dengan arsitektur VGG16 dan *MobileNet* dipilih untuk diterapkan pada sistem identifikasi kayu. Model arsitektur *MobileNet* setelah dilakukan proses *training* dan *testing*, memberikan hasil akurasi sebesar 96%, proses

*training* juga lebih cepat dari model arsitektur VGG16 yang memberikan hasil akurasi 90% (Feriawan *et al.*, 2020).

Penelitian lain terkait arsitektur *MobileNet* yang digunakan untuk deteksi penyakit daun padi menggunakan arsitektur *MobileNet*. Penelitian ini menggunakan 120 dataset yang berasal dari *UCI Repository* yang terdiri dari 3 jenis penyakit pada daun padi, yaitu *Bacterial leaf blight*, *Brown spot*, dan *Leaf smut*. Hasil akurasi yang diperoleh pelatihan setelah dilakukan pelatihan dan pengujian menggunakan citra penyakit daun padi dengan ukuran 224x224 piksel sebesar 1.0 dan akurasi validasi sebesar 0.8333. *Confusion Matrix* menyatakan bahwa tingkat akurasi mencapai 92% (Saputra *et al.*, 2021).

Penelitian sebelumnya terkait implementasi *Convolutional Neural Network* untuk mengidentifikasi pola batik. Penelitian ini menggunakan 6 motif batik untuk diidentifikasi. Motif batik yang dipakai yaitu, Banji, Ceplok, Kawung, Mega Mendung, Parang, dan Sekar Jagad. *Dataset* terdiri dari 994 gambar dari 6 kategori dikumpulkan dan kemudian dibagi menjadi data pelatihan dan uji dengan perbandingan 8:2. Penelitian ini juga menerapkan augmentasi data untuk mencegah *overfitting*. Hasil percobaan pengujian data menunjukkan bahwa CNN bekerja dengan sangat baik, seperti yang ditunjukkan oleh akurasi 94% yang dicapai dengan arsitektur jaringan *DenseNet*, dengan akurasi 2 teratas adalah 99%. (Rasyidi dan Bariyah, 2020). Penelitian sebelumnya yang lain meneliti klasifikasi motif Batik Lampung dengan *k-Nearest Neighbor* (k-NN). Motif Batik Lampung yang dipakai dalam penelitian ini terdiri dari Jung Agung, Siger Kembang Cengkih, Siger Ratu Agung, dan Sembagi. Ukuran data dikurangi menjadi 50 x 50 piksel dan kemudian diubah menjadi *Grayscale*. Untuk mengidentifikasinya, fungsi GLCM (*Gray Level Co-Occurrence Matrix*) diekstrak dan k-NN dengan nilai  $k = 3, 5, 7, 9, 11$  dan sudut orientasi  $0^\circ, 45^\circ, 90^\circ, 135^\circ$  digunakan untuk klasifikasi utama. Akurasi terbaik didapat dengan laju 97,96% untuk nilai  $k = 7$  dan sudut  $135^\circ$  (Andrian, Naufal, *et al.*, 2019).

Penelitian yang akan dilakukan yaitu perbandingan kinerja arsitektur

*Convolutional Neural Network (CNN) LeNet* dan *MobileNet* pada identifikasi citra Batik Lampung. Penelitian ini menggunakan dataset Batik Lampung dengan 8 kelas yaitu, Siger Kembang Cengkih, Jung Agung, Sembagi, Siger Ratu Agung, Granitan, Pakjimo, Siger Tangkup Betik, dan Soga. Penelitian ini dilakukan agar dapat mengetahui tingkat akurasi dari hasil perbandingan dua arsitektur terhadap citra Batik Lampung.

## **1.2 Rumusan Masalah**

Rumusan Masalah dari penelitian ini adalah bagaimana perbandingan tingkat akurasi identifikasi Batik Lampung dengan menggunakan arsitektur *LeNet* dan *MobileNet*.

## **1.3 Batasan Masalah**

Batasan masalah yang terdapat pada penelitian ini adalah menggunakan *dataset* Batik Lampung yang terdiri dari 10 kelas, yaitu Siger Kembang Cengkih, Jung Agung, Sembagi, Siger Ratu Agung, Granitan, Abstrak, Kambil Sicukil, Sekar Jagat, Sinaran, dan Tambal.

## **1.4 Tujuan Penelitian**

Tujuan dari dilakukannya penelitian ini adalah membandingkan kinerja arsitektur *Convolutional Neural Network (CNN) LeNet* dan *MobileNet* pada identifikasi citra Batik Lampung.

## 1.5 Manfaat Penelitian

Manfaat yang diperoleh dari penelitian ini adalah dapat dijadikan sebagai bahan referensi untuk penelitian lainnya mengenai pengidentifikasian citra Batik Lampung menggunakan *Convolutional Neural Network* (CNN).



## II. TINJAUAN PUSTAKA

### 2.1 Batik

Batik adalah kerajinan kain yang dihias dengan pola, warna, tulisan atau cap. Akhiran “tik” pada kata “batik” berasal dari kata menitik atau menetes. Batik dalam bahasa kuno disebut serat dan dalam bahasa *ngoko* artinya “menulis” atau menulis dengan lilin. Teknik membuat batik adalah proses pengerjaan mulai dari penyiapan kain sampai dengan pembuatan kain ikat celup. Batik juga merupakan salah satu ikon budaya Indonesia yang dianugerahi UNESCO *Heritage Award* pada 2 Oktober 2009. Batik adalah bentuk seni Indonesia yang dibuat dengan menggunakan teknik menggambar tradisional pada bahan (Amanah, 2014).

#### 2.1.1 Batik Lampung



Gambar 1. Batik Lampung (Sembagi).

Lampung awalnya tidak memiliki tradisi membatik, namun ada kain yang disebut Kain Sembagi, yang merupakan batik pertama yang digunakan oleh masyarakat Lampung. Citra dari kain sembagi dapat dilihat pada gambar 1. Sembagi adalah kain asli China yang sudah digunakan oleh masyarakat Lampung sejak

zaman Kerajaan Sriwijaya. Motif kain sebagian besar menonjolkan alam, seperti bunga dan daun (Andrian, Hermanto, *et al.*, 2019).

Perkembangan batik di Lampung cukup pesat untuk memenuhi kebutuhan Lampung dan sekitarnya. Pakaian adat yang cukup megah dan berat juga sangat mempengaruhi perkembangan batik yang praktis, ringan dan sangat nyaman dipakai (Wulandari, 2022).

#### **2.1.1.1 Batik Sembagi**



Gambar 2. Batik Sembagi.

Motif pada batik ini memiliki motif mayoritas kembang sembagi (Sapuan, 2023). Citra batik Sembagi dapat dilihat pada gambar 2.

#### **2.1.1.2 Batik Granitan**



Gambar 3. Batik Granitan.

Citra Batik Granitan dapat dilihat pada gambar 3. Batik Granitan tidak memiliki motif khusus, namun batik Granitan memiliki ciri khas dari Teknik pembuatannya

dan identik dengan titik-titik di pinggir motif. Batik Granitan juga digunakan sebagai kain adat pada acara adat atau upacara resmi di Lampung (Sapuan, 2023).

#### 2.1.1.3 Batik Jung Agung



Gambar 4. Batik Jung Agung.

Motif yang terdapat pada batik Jung Agung didominasi oleh motif jung atau kapal. Batik Jung Agung biasanya menggunakan warna-warna cerah dan kontras tinggi seperti merah, hijau, kuning, dan biru (Sapuan, 2023). Citra batik Jung Agung dapat dilihat pada gambar 4.

#### 2.1.1.4 Batik Kembang Cengkih



Gambar 5. Batik Kembang Cengkih.

Batik Kembang Cengkih memiliki ciri khas dengan corak kembang cengkih yang terkesan natural dan segar. Citra batik Kembang Cengkih dapat dilihat pada gambar 5. Motif kembang cengkih tersebut dihiasi dengan kembang atau bunga liar yang mengalir di sekitarnya. Batik ini biasanya menggunakan warna-warna

cerah seperti merah, hijau, dan kuning, dengan latar belakang putih atau abu-abu (Sapuan, 2023).

#### 2.1.1.5 Batik Kambil Sicukil



Gambar 6. Batik Kambil Sicukil.

Batik Kambil Sicukil memiliki motif ikon di dalam segitiga (Sapuan, 2023). Citra batik Kambil Sicukil dapat dilihat pada gambar 6.

#### 2.1.1.6 Batik Siger Ratu Agung



Gambar 7. Batik Siger Ratu Agung.

Citra Batik Siger Ratu Agung dapat dilihat pada gambar 7. Batik Siger Ratu Agung motifnya identik dengan motif pengantin. Motif batik ini terinspirasi dari keindahan dan keanggunan siger atau mahkota yang dikenakan oleh ratu Lampung serta simbol keagungan dan kekuasaan (Sapuan, 2023).

### 2.1.1.7 Batik Abstrak



Gambar 8. Batik Abstrak.

Batik Abstrak memiliki ciri khas berbagai macam motif ditambahkan ke dalam satu batik, contohnya motif daun, motif garis, warna polos dan lainnya (Sapuan, 2023). Citra batik Abstrak dapat dilihat pada gambar 8.

### 2.1.1.8 Batik Sekar Jagat



Gambar 9. Batik Sekar Jagat.

Batik Sekar Jagat memiliki ciri khas motif mirip dengan batik Kambil Sicukil, yaitu identik dengan motif ikon di dalam suatu bentuk sembarang (Sapuan, 2023). Citra batik Sekar Jagat dapat dilihat pada gambar 9.

### 2.1.1.9 Batik Sinaran



Gambar 10. Batik Sinaran.

Batik Sinaran dinamakan “sinaran” dikarenakan memiliki ciri khas motif garis membentuk kerucut seperti sinar (Sapuan, 2023). Citra batik Sinaran dapat dilihat pada gambar 10.

### 2.1.1.10 Batik Tambal



Gambar 11. Batik Tambal.

Batik Tambal memiliki ciri khas motif ikon di dalam bentuk persegi seperti beberapa potong kain yang ditambal menjadi satu (Sapuan, 2023). Citra batik Tambal dapat dilihat pada gambar 11.

## 2.2 *Supervised Learning dan Unsupervised Learning*


*Supervised learning* dan *unsupervised learning* adalah dua pendekatan penting dalam dunia *deep learning*. *Supervised learning* melibatkan pengawasan atau anotasi data dalam proses pelatihan. Model jaringan saraf mendapatkan panduan yang jelas dari label atau keluaran yang sesuai dengan setiap contoh pelatihan dalam *supervised learning*, hal ini memungkinkan model untuk memahami hubungan antara *input* dan *output*, sehingga dapat memprediksi dengan tepat saat dihadapkan pada data baru (Zeithml, 2021).

*Unsupervised learning* adalah tentang mengeksplorasi struktur dalam data tanpa panduan label. Model jaringan saraf mencoba untuk mengidentifikasi pola, korelasi, atau fitur-fitur yang tersembunyi dalam data, sering kali dengan mengelompokkan data menjadi kelompok-kelompok yang lebih homogen dalam *unsupervised learning*, hal ini membuatnya berguna untuk tugas seperti pengelompokan data (*clustering*) atau reduksi dimensi, di mana tujuan utamanya adalah memahami struktur internal dari data tanpa memiliki informasi label (Zeithml, 2021).

## 2.3 *Convolutional Neural Network*

*Convolutional Network* atau *Convolutional Neural Network* (CNN) adalah *neural network* untuk pemrosesan data dengan topologi *grid*. CNN pada umumnya memiliki 3 *layer*, yaitu *Convolutional*, *Pooling*, dan *Fully-Connected*. *Layer convolutional* terdiri dari beberapa neuron yang disusun untuk membentuk *filter*. *Filter* ini diterapkan menggunakan input titik di bagian area gambar input yang disebut *receptive field*, sehingga menghasilkan *result* atau *activation map* atau *feature map*. Jumlah peta fungsi peta yang dibuat sesuai dengan jumlah *filter* yang digunakan. *Pooling layer* biasanya ditempatkan di antara *convolution layer* untuk mengurangi parameter *feature map* agar komputasi berjalan lebih cepat tanpa mengorbankan informasi penting yang dikandungnya. Tujuan mendasar lainnya

adalah untuk mengurangi kemungkinan *overfitting*. *Feature map* yang dihasilkan masih berupa *array* multidimensi, sehingga diratakan sebagai input ke lapisan yang terhubung sepenuhnya dalam bentuk vektor, yang kemudian berisi beberapa *hidden layer*, fungsi aktivasi, dan *output layer* (Tumewu *et al.*, 2020). *Layer* dalam CNN dapat dilihat pada gambar 12.



Gambar 12. Model CNN (Alzubaidi *et al.*, 2021).

CNN bekerja secara otomatis untuk merekam karakteristik dari suatu objek, serta membentuk *pixel* untuk menyimpan karakteristik dari citra tersebut. Pekerjaan otomatis ini dapat dilakukan dengan algoritma CNN dan kerangka komputasi. Algoritma ini tersusun dari dua komponen utama, yaitu *feature extraction layer* dan *fully-connected layer* (Almryad dan Kutucu, 2020).

### 2.2.1 *Feature Extraction Layer*

*Feature extraction layer* adalah *layer* atau lapisan di dalam CNN yang bertugas melakukan ekstraksi ciri dan menyimpannya menjadi *pixel* dalam sebuah *array*. *Feature Extraction Layer* terdapat dua lapisan utama yaitu *convolutional layer*, dan *pooling layer*. Fungsi aktivasi yang digunakan pada *layer* ini, yaitu ReLU. Jumlah *layer* untuk memberikan akurasi yang baik membutuhkan banyak percobaan. Urutan *layer* tidak selalu sama (Ridho Aji Pangestu *et al.*, 2020). Berikut penjelasan mengenai masing-masing lapisan :



### 2.2.1.1 *Convolutional Layer*

*Convolutional Layer* adalah suatu proses yang pada saat penyederhanaan nilai pada citra masukan, sekaligus menyimpan fitur citra melalui nilai *pixel* yang diperoleh dari proses penyederhanaan. Penyederhanaan dilakukan dengan mengalikan antara matriks input dan filter. Input citra akan memiliki nilai *pixel* berupa larik multidimensi yang perlu disederhanakan, setelah itu dapat dilakukan penyederhanaan nilai tanpa menghilangkan informasi utama fitur-fitur menggunakan penggunaan filter. Hasil dari *convolutional layer* ini juga bisa disebut dengan *feature map* atau peta fitur (Ridho Aji Pangestu *et al.*, 2020).

### 2.2.1.2 *Pooling Layer*

*Pooling layer* atau *subsampling layer* biasanya langsung mengikuti lapisan konvolusional di CNN. Perannya adalah untuk mengecilkan output dari lapisan konvolusional sepanjang dimensi spasial tinggi dan lebar (Ridho Aji Pangestu *et al.*, 2020). Proses *pooling* biasanya mengambil nilai maksimum (*max pooling*) atau rata-rata (*average pooling*) dari piksel-piksel dari *feature map* yang dibuat oleh *convolutional layer* (Irfansyah *et al.*, 2021).

### 2.2.2 *Fully-connected Layer*

*Fully-connected layer* adalah lapisan dalam CNN yang digunakan untuk tahapan klasifikasi objek gambar. Hasil klasifikasi terhadap kelas objek bisa didapatkan pada *layer* ini karena *layer* ini merupakan *layer* terakhir dalam CNN. *Layer* ini melakukan proses klasifikasi dan menggunakan fungsi aktivasi seperti ReLU dan Sigmoid. Pada output *layer*, menggunakan fungsi *softmax* menghasilkan nilai kerugian probabilistik menggunakan skor yang dihasilkan oleh model (Ridho Aji Pangestu *et al.*, 2020). Penjelasan mengenai fungsi ReLU dan *softmax* sebagai berikut :

#### a. *Rectified Linear Unit (ReLU) Activation*


ReLU atau *Rectified Linear Unit* adalah salah satu fungsi aktivasi. Tugas ReLU adalah menghilangkan nilai negatif dari gambar. Fungsi aktivasi ReLU bekerja dengan mengganti nilai negatif pada gambar atau *feature map* dengan 0 (Ridho Aji Pangestu *et al.*, 2020).

### b. *Softmax Activation*

Aktivasi *softmax* merupakan fungsi matematis yang sering digunakan pada jaringan saraf tiruan, khususnya pada lapisan keluaran model klasifikasi. Fungsi ini digunakan untuk mengubah nilai keluaran model menjadi distribusi probabilitas antar kelas yang diprediksi. Fungsi *softmax* mengambil vektor nilai bilangan real dan mengubahnya menjadi distribusi probabilitas, di mana setiap skor diubah menjadi nilai probabilitas antara 0 dan 1, dan jumlah semua probabilitas adalah 1 (Ridho Aji Pangestu *et al.*, 2020).

## 2.4 *LeNet*

*LeNet-5* adalah jaringan *multilayer* berbasis CNN yang diperkenalkan oleh Yann LeCun. *LeNet-5* merupakan evolusi dari *LeNet* yang telah ada sebelumnya, di mana *LeNet-5* memiliki lebih banyak parameter bebas atau lapisan yang lebih banyak dari pendahulunya. Peningkatan jumlah parameter ini disebabkan oleh meningkatnya kecepatan atau teknologi komputer yang memungkinkan untuk melakukan perhitungan matematis dengan lebih cepat (Fitriati, 2016).



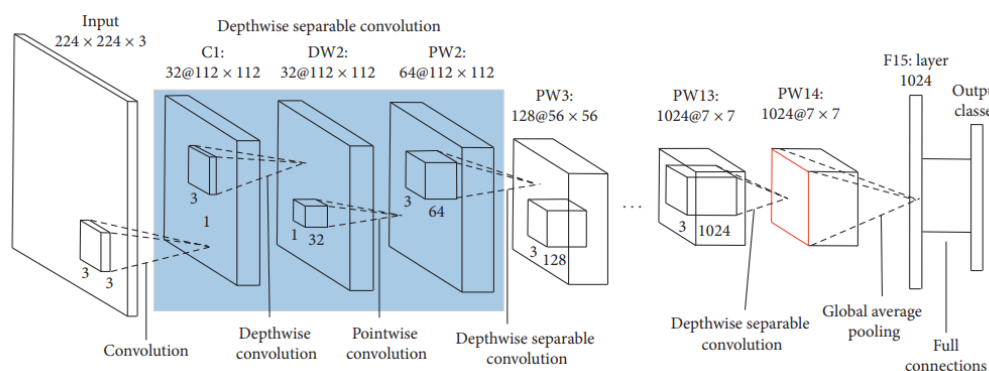
Gambar 13. Arsitektur *LeNet-5* (Mustamin *et al.*, 2021).

Struktur dari *LeNet-5* dapat dilihat pada gambar 13. *LeNet-5* memiliki 6 lapisan, yaitu *layer input* yang menerima gambar, dua *convolutional layer* untuk mengekstraksi fitur pada citra, dua *pooling* atau *subsampling layer* untuk mengurangi dimensi gambar menjadi setengahnya, dan *fully-connected layer* untuk meratakan *output* dari *layer* sebelumnya menjadi sebuah vektor kemudian melakukan operasi matematis untuk menghasilkan fitur atau ciri yang lebih

kompleks. *LeNet-5* sering digunakan dalam pengenalan pola yang lebih kompleks, seperti pada pengenalan wajah atau objek (Mustamin *et al.*, 2021).

## 2.5 *MobileNet*

*MobileNet* adalah arsitektur jaringan saraf tiruan yang dikembangkan khusus untuk tugas klasifikasi gambar pada perangkat *mobile*. Arsitektur *MobileNet* dirancang untuk memberikan kinerja tinggi pada perangkat seluler dengan sumber daya terbatas seperti *smartphone* dan tablet. Arsitektur ini menggunakan *Depthwise Separable Convolution* untuk mengurangi jumlah parameter dan perhitungan yang diperlukan untuk melatih dan menjalankan model. *MobileNet* apabila dibandingkan dengan arsitektur CNN yang lebih besar seperti VGG dan ResNet, *MobileNet* dapat memberikan kinerja yang sebanding atau bahkan lebih baik dalam beberapa tugas dengan ukuran dan kompleksitas model yang lebih kecil. Ukuran dan kompleksitas model yang lebih kecil membuat *MobileNet* lebih cocok untuk digunakan pada perangkat seluler dengan sumber daya terbatas. Struktur dari *MobileNet* dapat dilihat pada gambar 14.



Gambar 14. Arsitektur *MobileNet* (Wang *et al.*, 2020).

Struktur dari *MobileNet* terdiri dari *input layer*, *convolutional layer*, *depthwise separable convolutional layer*, *fully-connected layer*, dan *output layer*. *Input layer* memiliki fungsi untuk menerima citra dengan ukuran tertentu. *MobileNet* menggunakan lapisan konvolusi yang dibuat pada gambar dengan *filter* yang

relatif kecil (3x3). *Filter* yang digunakan di setiap lapisan konvolusi adalah *filter* yang dapat dipelajari untuk memungkinkan model mempelajari fitur penting dari citra atau gambar. *Depthwise separable convolutional layer* terdiri dari dua tahap, tahap yang pertama adalah *depthwise convolution* yang menerapkan *filter* ke setiap saluran *input* secara terpisah. Tahap yang kedua adalah *pointwise convolution* yang mengkombinasikan *output* dari *depthwise convolution* menjadi fitur-fitur baru. *Depthwise separable convolutional layer* sangat efisien karena mengurangi jumlah parameter dan operasi komputasi. *Output* dari lapisan terakhir digunakan sebagai *input* untuk *fully-connected layer*, yang bertujuan untuk mengklasifikasikan citra ke dalam kelas-kelas tertentu. Lapisan keluaran atau *output layer* menghasilkan prediksi, yang merupakan probabilitas kemungkinan kelas dari gambar yang diberikan (Nufus *et al.*, 2021).

## 2.6 Augmentasi Data

Banyak strategi yang digunakan untuk mengurangi *overfitting*, salah satunya adalah augmentasi data, yang bertujuan untuk meningkatkan jumlah data dengan cara yang paling efisien. Tujuan dari augmentasi data adalah menghasilkan variasi baru dari dataset asli guna melengkapi variasi data yang ada, baik untuk melatih model baru maupun meningkatkan kinerja model yang sudah ada. Data diaugmentasi dengan melakukan transformasi pada data yang ada atau dengan membuat salinan dari sumber data tanpa mengubah label pada setiap bagian data tersebut (Fadillah *et al.*, 2021).

Augmentasi data melibatkan manipulasi transformasi dimensi pada gambar yang ada untuk meningkatkan variasi dalam *dataset*. Variasi yang lebih besar dapat dicapai tanpa perlu mengumpulkan jumlah data yang sebenarnya lebih besar dengan menggunakan teknik ini. Misalnya, dengan melakukan rotasi, pemangkasan, pergeseran, atau memvariasikan parameter lainnya pada gambar, dapat menciptakan variasi baru tanpa harus mengumpulkan sampel data tambahan. Hasilnya adalah *dataset* yang lebih beragam, yang membantu meningkatkan

kinerja model dan mengurangi masalah *overfitting*. Pentingnya augmentasi data terletak pada kemampuannya dalam mengatasi keterbatasan sampel data, terutama pada kumpulan data gambar. Data merupakan materi dasar bagi setiap algoritma pembelajaran mesin, serupa dengan cara algoritma diberi asupan, sehingga setiap kekurangan data dan labelnya berpotensi mempengaruhi ketepatan model yang diajukan dalam konteks pembelajaran mesin. Strategi pelatihan seperti augmentasi gambar menjadi salah satu cara efektif untuk memperluas kumpulan gambar bagi model jaringan saraf, tanpa perlu memasukkan gambar tambahan secara langsung (Khalifa *et al.*, 2022).

Augmentasi data dapat membantu model untuk generalisasi dengan lebih baik pada data yang belum pernah dilihat sebelumnya. Ukuran dataset dapat diperluas dengan menggunakan dengan cara yang efisien, sambil tetap mempertahankan label yang sama pada setiap bagian data yang dihasilkan (Sanjaya dan Ayub, 2020). Masalah akurasi rendah dalam pengklasifikasian multi kelas serta isu ketidakseimbangan data dapat ditemukan solusinya melalui penerapan metode pre-processing dan augmentasi citra yang sesuai, yang telah diidentifikasi melalui serangkaian eksperimen (Patil *et al.*, 2023).

### 2.6.1 *Rotation*

Augmentasi rotasi digunakan untuk memutar gambar sejauh sudut tertentu. Teknik ini bertujuan untuk menghasilkan variasi data baru dengan memutar objek yang terdapat dalam gambar, dengan tujuan melatih atau meningkatkan kinerja model dalam pengenalan objek atau pengolahan citra (Shorten dan Khoshgoftaar, 2019). Augmentasi *rotation* dapat dilihat pada gambar 15.



Gambar 15. Augmentasi *Rotation* (Lee, 2022).

### 2.6.2 *Brightness*

Penambahan kecerahan adalah metode pengolahan gambar yang digunakan untuk meningkatkan atau mengurangi tingkat kecerahan suatu gambar. Tujuan utamanya adalah memperbaiki kualitas visual atau menyesuaikan pencahayaan gambar agar sesuai dengan keinginan atau preferensi pengguna (Kandel *et al.*, 2022). Augmentasi *brightness* dapat dilihat pada gambar 16.



Gambar 16. Augmentasi *Brightness* (Lee, 2022).

### 2.6.3 *Zoom*

Pembesaran atau perkecilan gambar, yang juga dikenal sebagai skala augmentasi, merupakan teknik pengolahan citra yang digunakan untuk mengubah ukuran suatu gambar. Tujuannya adalah untuk memodifikasi ukuran relatif objek dalam gambar tanpa mengubah proporsi atau aspek penting lainnya (Lasniari *et al.*, 2022). Augmentasi *zoom* dapat dilihat pada gambar 17.



Gambar 17. Augmentasi *Zoom* (Lee, 2022).

## 2.7 *Hyperparameter*

*Hyperparameter* dalam *convolutional neural network* (CNN) adalah parameter yang tidak dipelajari oleh model selama proses *training*, namun harus ditentukan secara manual oleh pengguna sebelum model di-*training*. *Hyperparameter*

penting karena dapat memengaruhi performa dan akurasi model. Pemilihan *hyperparameter* yang tepat sangat penting untuk mengoptimalkan kinerja model CNN. Pemilihan *hyperparameter* dapat dilakukan dengan mencoba berbagai kombinasi *hyperparameter* dan memilih salah satu yang paling sesuai untuk data validasi. *Hyperparameter* yang sering digunakan dalam arsitektur CNN antara lain, *epoch*, *batch-size*, *optimizer*, dan *learning rate* (Rochmawati *et al.*, 2021).

### **2.7.1 Epoch**

*Epoch* mengacu pada berapa kali dataset pelatihan diproses oleh jaringan saraf. Setiap *epoch* terdiri dari serangkaian langkah-langkah pelatihan di mana bobot jaringan saraf disesuaikan untuk meminimalkan nilai fungsi kerugian. Jumlah *epoch* optimal untuk CNN bergantung pada kompleksitas masalah dan ukuran *dataset*. Semakin besar dan kompleks *dataset*, semakin banyak *epoch* yang diperlukan untuk mencapai hasil yang optimal (Wibawa, 2017).

### **2.7.2 Batch-size**

*Batch-size* mengambil jumlah sampel dari data pelatihan yang akan dilatih secara batch. Batch dibuat untuk melakukan prosedur satu iterasi. Iterasi adalah pembacaan data dari depan ke belakang (Rochmawati *et al.*, 2021).

### **2.7.3 Optimizer Adam**

*Optimizer Adam (Adaptive Moment Estimation)* adalah algoritma *optimizer* yang sering digunakan dalam *training neural network*. *Optimizer Adam* merupakan perkembangan dari algoritma Stochastic Gradient Descent (SGD) klasik dimana bobot network telah diperbarui. Penggunaan algoritma *optimizer Adam* perlu penentuan besaran learning rate yang akan digunakan pada saat *training dataset* (Rochmawati *et al.*, 2021).

### **2.7.4 Learning-rate**

*Learning rate* merupakan salah satu parameter *training* yang ditetapkan untuk menghitung nilai koreksi bobot selama proses *training*. Pemilihan *learning rate* merupakan tantangan tersendiri karena jika nilainya terlalu kecil proses *training*

akan memakan waktu yang lebih lama sedangkan jika terlalu besar proses *training* akan kurang optimal karena terlalu cepat dan proses *training* menjadi tidak stabil (Rochmawati *et al.*, 2021).

## 2.8 *Overfitting*

*Overfitting* adalah sebuah istilah yang digunakan dalam *machine learning* dan statistik untuk menggambarkan situasi di mana sebuah model pembelajaran mesin terlalu "memahami" atau "menghafal" data pelatihan dengan sangat baik, sehingga menciptakan representasi yang kurang umum atau tidak sesuai dengan data yang sebenarnya. *Overfitting* ini adalah salah satu masalah utama dalam pembelajaran mesin dan dapat mengakibatkan performa yang buruk pada data baru atau data yang tidak terlihat sebelumnya (Ashiquzzaman *et al.*, 2017).

## 2.9 *Confusion Matrix*

*Confusion matrix* adalah tabel yang digunakan untuk mengevaluasi kinerja algoritma klasifikasi terhadap masalah klasifikasi. *Confusion matrix* menampilkan jumlah klasifikasi benar dan salah untuk setiap jenis soal. *Confusion matrix* terdiri dari *accuracy*, *precision*, *recall*, dan *f1-score*. *Confusion matrix* memiliki ukuran evaluasi melalui 4 metrik utama, yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP) dan *false negative* (FN). Baris *confusion matrix* sesuai dengan kelas sebenarnya, sedangkan kolom sesuai dengan kelas prediksi. Diagonal matriks menunjukkan prediksi yang benar (*true positive* dan *true negative*), sedangkan elemen di luar diagonal menunjukkan prediksi yang salah (*false positive* dan *false negative*) (Maxwell *et al.*, 2021). Tabel *confusion matrix* bisa dilihat pada tabel 1.



Tabel 1. *Confusion Matrix* (Maxwell *et al.*, 2021)

		<i>Predicted Class</i>	
		<i>Positive</i>	<i>Negative</i>
<i>Actual Class</i>	<i>Positive</i>	TP	FN
	<i>Negative</i>	FP	TN

Keterangan :

- TP (*True Positive*), yaitu model memprediksi dengan benar sebuah kelas (*positive*) sebagai kelas sebenarnya (*positive*)
- FP (*False Positive*), yaitu model memprediksi dengan salah sebuah kelas (*negative*) sebagai kelas lain (*positive*)
- TN (*True Negative*), yaitu model memprediksi dengan benar sebuah kelas (*negative*) sebagai kelas sebenarnya (*negative*)
- FN (*False Negative*), yaitu model memprediksi dengan salah sebuah kelas (*positive*) sebagai kelas lain (*negative*)

Perhitungan yang dipakai dalam *confusion matrix* adalah sebagai berikut :

- *Accuracy*

*Accuracy* adalah metrik paling umum yang digunakan untuk mengevaluasi pengklasifikasi, *accuracy* mengevaluasi kinerja keseluruhan dari suatu algoritma dengan memperkirakan probabilitas nilai sebenarnya dari label kelas (Bekkar *et al.*, 2013). Perhitungan yang dipakai untuk mengukur tingkat akurasi dapat dilihat pada rumus (1).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (1)$$

- *Precision*

*Precision* adalah ukuran kinerja model klasifikasi yang dapat dihitung dengan menggunakan *confusion matrix*. *Precision* mengukur berapa banyak dari semua prediksi positif yang benar-benar positif. *True Positive* (TP) mewakili jumlah data positif yang benar-benar diklasifikasikan oleh model dengan benar, sedangkan *False Positive* (FP) mewakili jumlah data negatif yang salah diklasifikasikan

sebagai positif oleh model (Maxwell *et al.*, 2021). Perhitungan yang dipakai untuk mengukur *precision* dapat dilihat pada rumus (2).

$$Precision = \frac{TP}{TP+FP} \times 100\% \quad (2)$$

- *Recall*

*Recall* adalah metrik evaluasi kinerja model pengklasifikasi yang dapat dihitung menggunakan *confusion matrix*. *Recall* mengukur berapa banyak data positif yang sebenarnya dideteksi model (Maxwell *et al.*, 2021). Perhitungan yang dipakai untuk mengukur *recall* dapat dilihat pada rumus (3).

$$Recall = \frac{TP}{TP+FN} \times 100\% \quad (3)$$

- *F1-Score*

*F1-score* adalah metrik yang menggabungkan nilai *precision* dan *recall* menjadi satu nilai tunggal yang dapat memberikan gambaran keseluruhan tentang kinerja model. *F1-score* mencapai keseimbangan antara *precision* dan *recall* dengan mengevaluasi kinerja model terhadap rata-rata yang diselaraskan dari kedua metrik ini (Maxwell *et al.*, 2021). Perhitungan yang dipakai untuk mengukur *F1-score* dapat dilihat pada rumus (4).

$$F1-score = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \quad (4)$$

### III. METODOLOGI PENELITIAN

#### 3.1 Waktu dan Tempat

Waktu dan tempat penelitian akan ditetapkan sebagai berikut :

##### 3.1.1 Waktu Penelitian

Penelitian dilakukan pada bulan Mei tahun ajaran 2022/2023 sampai dengan bulan Juli tahun ajaran 2022/2023.

Waktu penelitian akan dijelaskan dengan tabel *gantt chart* pada tabel 2.

Tabel 2. Rencana Penelitian

Nama Kegiatan	2023									
	Mei		Juni				Juli			
	3	4	1	2	3	4	1	2	3	4
Pengumpulan <i>dataset</i>	■	■								
Pelabelan <i>dataset</i>		■	■							
Pemrograman model <i>LeNet-5</i> dan <i>MobileNet</i>			■	■	■	■	■			
Pengujian <i>dataset</i>			■	■	■	■	■			
Hasil pengujian							■	■		
Penulisan Laporan									■	■

##### 3.1.2 Tempat Penelitian

Penelitian ini dilaksanakan di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Laboratorium Rekayasa Perangkat Lunak (Lab

RPL) FMIPA dan Batik Siger, Beringin Raya, Kecamatan Kemiling, Kota Bandar Lampung, Lampung.

## **3.2 Alat dan Bahan**

Alat dan bahan pendukung yang digunakan dalam penelitian ini adalah sebagai berikut :

### **3.2.1 Alat Penelitian**

Penelitian ini memerlukan beberapa peralatan yang akan mendukung proses penelitian. Alat yang dibutuhkan antara lain perangkat lunak (*software*) dan perangkat keras (*hardware*).

#### **3.2.1.1 Perangkat Lunak (*Software*)**

Pendukung perangkat lunak yang digunakan dalam proses identifikasi citra Batik Lampung adalah sistem operasi *Windows 10 64-bit*, *Google Colab*, *Jupyter Notebook*, dan *Google Drive*.

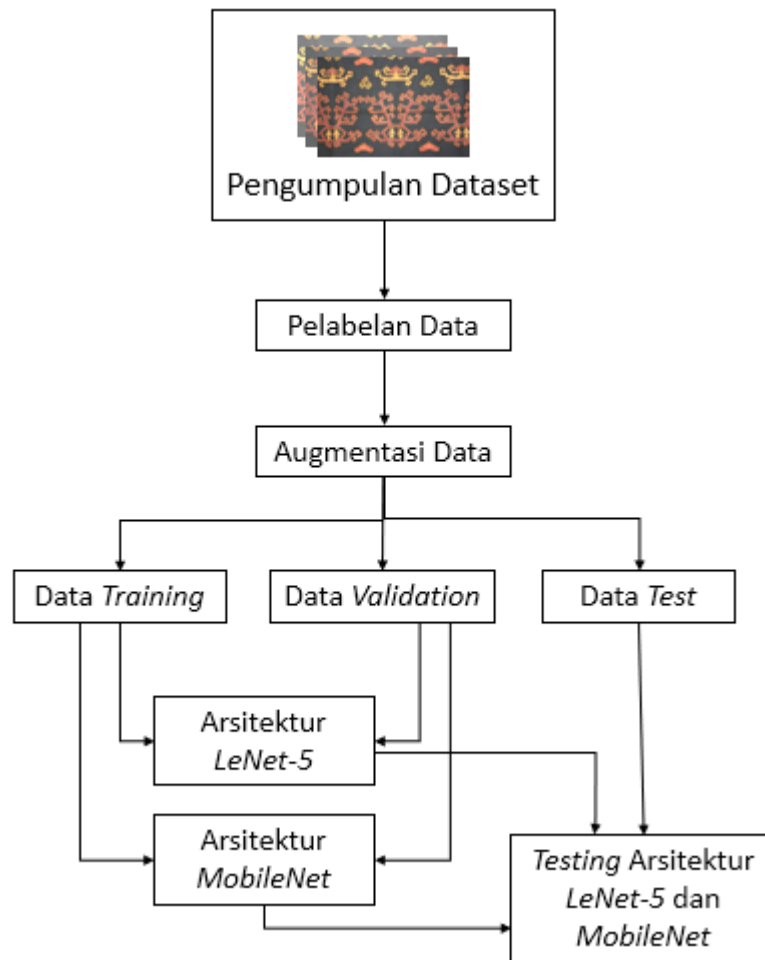
#### **3.2.1.2 Perangkat Keras**

Pendukung perangkat keras yang digunakan dalam proses identifikasi citra Batik Lampung adalah kamera Canon EOS 250D, komputer dengan GPU NVIDIA Tesla K80 dan laptop Acer Aspire E 14 dengan spesifikasi RAM 8.00 GB, HDD 1 TB, dan *processor Intel Core i5-8250U CPU 1.60GHz*.

### **3.2.2 Bahan Penelitian**

Penelitian ini menggunakan *dataset* berisi citra Batik Lampung. Citra Batik Lampung yang digunakan sebanyak 500 citra dengan kelas sebanyak 10 dan masing-masing kelas memiliki 50 citra. *Dataset* diperoleh dari Batik Siger, Beringin Raya, Kecamatan Kemiling, Kota Bandar Lampung, Lampung.

### 3.3 Metode



Gambar 18. Alur Penelitian.

Tahapan yang dilakukan dalam penelitian ini dapat dilihat pada gambar 18 dan penjelasannya sebagai berikut :

#### 3.3.1 Pengumpulan *Dataset*

Tahap yang pertama yang dilakukan dalam penelitian adalah mengumpulkan *dataset* sebagai bahan untuk penelitian. *Dataset* yang dikumpulkan sebanyak 500 citra batik lampung dengan 10 kelas. Citra disimpan dalam *google drive* untuk mempermudah pemanggilan dan penggunaan data ke *google colab*. Citra batik lampung juga disimpan dalam komputer Tesla. Setiap citra batik lampung disimpan ke dalam folder yang berbeda sesuai dengan label masing-masing kelas

*dataset*, yang tertera pada nama folder. Mesin akan membaca *dataset* di awal proses, baik citra batik lampung maupun nama kelas yang tertera pada tiap foldernya.

### 3.3.2 Pelabelan Data

Pelabelan data merupakan salah satu tahap dalam pengembangan model *deep learning*. Data harus diberi label atau anotasi yang sesuai sehingga model dapat memahami dan mempelajari pola yang ada. Pelabelan data adalah proses menandai atau mengkategorikan setiap elemen data, seperti gambar, teks, atau suara, dengan label yang mencerminkan informasi yang ingin dipelajari oleh model.

### 3.3.3 Augmentasi Data

Augmentasi data digunakan sebagai metode untuk mengatasi *overfitting* serta menambahkan variasi pada data pembelajaran model. Augmentasi juga diterapkan untuk membandingkan akurasi antara model sebelum dan setelah augmentasi dilakukan. Ada beberapa jenis augmentasi data yang tersedia, penelitian ini menggunakan beberapa augmentasi data yaitu meliputi *rotate*, *brightness*, dan *zoom*. *Dataset* diperluas dengan melakukan *rotate*, *brightness*, dan *zoom*, menghasilkan 500 gambar tambahan, selain itu, ukuran data diubah menjadi 224 x 224 piksel. Pemilihan ukuran piksel gambar 224 x 224 memiliki tujuan yaitu, agar dapat digunakan sebagai standar membandingkan dan menguji kinerja model dengan *dataset* yang sama, kebutuhan memori dan ukuran model akan bertambah besar seiring bertambah besarnya piksel gambar yang digunakan, selain itu, ukuran gambar 224 x 224 masih cukup besar untuk model seperti *MobileNet* dan memungkinkan ekstraksi fitur yang cukup baik dari gambar tanpa mengorbankan terlalu banyak informasi. Gambar-gambar hasil augmentasi kemudian digabungkan dengan dataset awal, sehingga secara keseluruhan terdapat 1000 gambar yang digunakan untuk melatih dan menguji model. Penelitian ini hanya menggunakan tiga augmentasi data yang paling umum, apabila jenis augmentasi yang digunakan semakin banyak, maka semakin kompleks dan rumit pengaturan

dan pemantauannya, selain itu, terlalu banyak augmentasi dapat menjadi beban komputasi yang berat.

### **3.3.4 Pembagian Data**

Pembagian data yang dilakukan adalah membagi data menjadi 3 bagian utama, yaitu data *training*, data *validation* dan data *test*. Pembagian masing-masing data yang dipakai sebanyak 70% *data training*, 15% *data validation*, dan 15% *data test*. Tujuan utama dari pembagian ini adalah untuk memastikan bahwa pembagian yang dilakukan memiliki data yang cukup untuk pelatihan yang efektif, validasi yang baik untuk penyetelan model, dan pengujian yang dapat diandalkan untuk mengukur kinerja akhir.

#### **3.3.4.1 Data Training**

Data *training* digunakan sebagai bahan utama untuk melatih data. Bagian data *training* yang akan dipakai sebanyak 70% dari keseluruhan citra.

#### **3.3.4.2 Data Validation**

Data *validation* digunakan untuk memastikan kualitas dan kecocokan data sebelum digunakan dalam pelatihan atau pengujian model. Proses pelatihan menggunakan data *training* memerlukan validasi untuk membuktikan kesamaan data yang dibaca oleh model. Data *validation* yang digunakan dalam penelitian ini sebanyak 15% dari keseluruhan data gambar.

#### **3.3.4.3 Data Test**

Data *test* digunakan untuk melakukan proses pengujian pada model yang ada. Data *test* yang digunakan dalam penelitian ini sebanyak 15% dari jumlah keseluruhan data gambar.

### **3.3.5 Training Arsitektur LeNet-5 dan MobileNet**

Proses latih data atau pelatihan model menggunakan dua model utama yaitu *LeNet-5* dan *MobileNet* dengan data yang akan dilatih yaitu sebanyak 500 citra batik lampung. Proses latih data menggunakan alat *google colab*, mesin tesla k80

dan beberapa *hyperparameter* seperti *epoch*, *batch-size*, *optimizer*, dan *learning-rate*. Kedua model akan menggunakan *hyperparameter* yang sama sehingga hasil perbandingannya dapat terlihat. Nilai *hyperparameter* yang digunakan dapat dilihat pada tabel 3.

Tabel 3. *Hyperparameter*

<i>Hyperparameter</i>	Nilai
<i>Epoch</i>	20
<i>Batch-size</i>	32
<i>Optimizer</i>	Adam
<i>Learning-rate</i>	0,001

Kombinasi *hyperparameter* yang digunakan pada penelitian ini, didapatkan dari percobaan menggunakan beberapa teknik dari *library keras callbacks* seperti *ReduceLROnPlateau*, dan *EarlyStopping*. *ReduceLROnPlateau* adalah suatu teknik dalam *deep learning* yang digunakan untuk mengurangi tingkat pembelajaran (*learning rate*) saat pelatihan model mengalami stagnasi atau perlambatan dalam peningkatan kinerja, sedangkan *EarlyStopping* adalah teknik dalam pelatihan model *deep learning* yang digunakan untuk menghentikan pelatihan secara otomatis ketika tidak terjadi peningkatan dalam kinerja model di atas data validasi dalam beberapa *epoch* (iterasi pelatihan). *ReduceLROnPlateau* dan *EarlyStopping* digunakan untuk membantu dalam menentukan *learning rate* dan jumlah *epoch* yang digunakan, sedangkan untuk jumlah *batch size* yang digunakan didapatkan dari beberapa percobaan yang menghasilkan kinerja paling baik.

### 3.3.6 *Testing arsitektur LeNet-5 dan MobileNet*

Tahapan evaluasi arsitektur menggunakan data *testing* yang telah diperoleh dan dilakukan setelah pelatihan model terhadap data *training* dan data *validation* selesai. Hasil dari klasifikasi akan dicatat dan dilakukan perbandingan pada tahap selanjutnya.



## V. SIMPULAN DAN SARAN

### 5.1 Simpulan

Simpulan yang didapatkan dari penelitian yang dilakukan adalah sebagai berikut :

1. Pengidentifikasian batik lampung menggunakan arsitektur *LeNet-5* dan *MobileNet* berhasil dilakukan dengan penambahan augmentasi data *rotate*, *brightness*, dan *zoom*. Akurasi tertinggi diperoleh oleh *LeNet-5* yaitu mencapai akurasi sebesar 99.33%, sedangkan *MobileNet* mencapai akurasi sebesar 98.00% pada mesin Tesla K80.
2. Arsitektur *LeNet-5* dengan penerapan augmentasi *rotate*, *brightness*, dan *zoom* pada mesin Tesla K80 mencapai hasil tertinggi dalam memprediksi kelas batik lampung dengan tepat (*precision*) dan dalam menemukan kelas secara akurat dari data uji (*recall*). Hasil penelitian menunjukkan bahwa rata-rata nilai *recall* mencapai 99,30%, sementara rata-rata nilai *precision* mencapai 99,40%.
3. Jumlah parameter pembelajaran pada *LeNet-5* lebih banyak dibandingkan *MobileNet*, dan tingkat akurasi tertinggi dihasilkan oleh *LeNet-5* dengan augmentasi data. Hal ini membuktikan efisiensi kinerja *LeNet-5* dengan jumlah parameter yang lebih tinggi untuk *dataset* batik lampung lebih baik.

### 5.2 Saran

Saran yang diberikan untuk penelitian selanjutnya adalah sebagai berikut :

1. Menambahkan lebih banyak ragam dari setiap kelas batik lampung dalam *dataset* untuk meningkatkan keberagaman data dan keakuratan model.

2. Mengeksplorasi penggunaan berbagai arsitektur CNN lainnya, seperti VGG-16, ResNet-50, *Inception*, *YOLOv5*, *DenseNet* atau arsitektur lainnya untuk dapat membandingkan hasil akurasi dengan arsitektur lainnya agar mendapatkan hasil yang optimal.

## DAFTAR PUSTAKA

- Almryad, A. S., & Kutucu, H. (2020). Automatic identification for field butterflies by convolutional neural networks. *Engineering Science and Technology, an International Journal*, 23(1), 189–195.  
<https://doi.org/10.1016/j.jestch.2020.01.006>
- Alwanda, M. R., Ramadhan, R. P. K., & Alamsyah, D. (2020). Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle. *Jurnal Algoritme*, 1(1), 45–56.  
<https://doi.org/10.35957/algoritme.v1i1.434>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. In *Journal of Big Data* (Vol. 8, Issue 1). Springer International Publishing. <https://doi.org/10.1186/s40537-021-00444-8>
- Amanah, A. (2014). Sejarah Batik Dan Motif Batik Di Indonesia. *Seminar Nasional Riset Inovatif II*, 2, 539–545.
- Andrian, R., Hermanto, B., & Kamil, R. (2019). The Implementation of Backpropagation Artificial Neural Network for Recognition of Batik Lampung Motive. *Journal of Physics: Conference Series*, 1338(1).  
<https://doi.org/10.1088/1742-6596/1338/1/012062>

- Andrian, R., Naufal, M. A., Hermanto, B., Junaidi, A., & Lumbanraja, F. R. (2019). K-Nearest Neighbor (k-NN) Classification for Recognition of the Batik Lampung Motifs. *Journal of Physics: Conference Series*, 1338(1). <https://doi.org/10.1088/1742-6596/1338/1/012061>
- Ashiquzzaman, A., Tushar, A. K., Islam, M. R., Shon, D., Im, K., Park, J. H., Lim, D. S., & Kim, J. (2017). Reduction of overfitting in diabetes prediction using deep learning neural network. *Lecture Notes in Electrical Engineering*, 449, 35–43. [https://doi.org/10.1007/978-981-10-6451-7\\_5](https://doi.org/10.1007/978-981-10-6451-7_5)
- Bakti, I., & Firdaus, M. (2023). Arsitektur Convolutional Neural Network InceptionResNet-V2 Untuk Pengelompokan Pneumonia Chest X-Ray. *Jurnal Komputer Dan Teknologi (JUKOMTEK)*, 01(02), 35–42.
- Bekkar, M., Djemaa, H. K., & Alitouche, T. A. (2013). Evaluation Measures for Models Assessment over Imbalanced Data Sets. *Journal of Information Engineering and Applications*, 3(10), 27–38. <http://www.iiste.org/Journals/index.php/JIEA/article/view/7633>
- Fadillah, R. Z., Irawan, A., Susanty, M., & Artikel, I. (2021). Data Augmentasi Untuk Mengatasi Keterbatasan Data Pada Model Penerjemah Bahasa Isyarat Indonesia (BISINDO). *Jurnal Informatika*, 8(2), 208–214. <https://ejournal.bsi.ac.id/ejurnal/index.php/ji/article/view/10768>
- Feriawan, J., Swanjaya, D., Informatika, T., Teknik, F., Nusantara, U., & Kediri, P. (2020). Perbandingan Arsitektur Visual Geometry Group dan MobileNet Pada Pengenalan Jenis Kayu. *Seminar Nasional Inovasi Teknologi UN PGRI*, 185–190.
- Fitriati, D. (2016). Perbandingan Kinerja Cnn Lenet 5 Dan Extreme Learning Machine Pada Pengenalan Citra Tulisan Tangan Angka. *Jurnal Teknologi Terpadu*, 2(1). <https://doi.org/10.54914/jtt.v2i1.45>

- Haksoro, E. I., & Setiawan, A. (2021). Pengenalan Jamur Yang Dapat Dikonsumsi Menggunakan Metode Transfer Learning Pada Convolutional Neural Network. *Jurnal ELTIKOM*, 5(2), 81–91.  
<https://doi.org/10.31961/eltikom.v5i2.428>
- Irfansyah, D., Mustikasari, M., & Suroso, A. (2021). Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi. *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*, 6(2), 87–92.  
<http://ejournal.poltektegal.ac.id/index.php/informatika/article/view/2802>
- Kandel, I., Castelli, M., & Manzoni, L. (2022). Brightness as an Augmentation Technique for Image Classification. *Emerging Science Journal*, 6(4), 881–892. <https://doi.org/10.28991/ESJ-2022-06-04-015>
- Khalifa, N. E., Loey, M., & Mirjalili, S. (2022). A comprehensive survey of recent trends in deep learning for digital images augmentation. *Artificial Intelligence Review*, 55(3), 2351–2377. <https://doi.org/10.1007/s10462-021-10066-4>
- Khasanah, C. U., Utami, E., & Raharjo, S. (2020, October 23). Implementation of Data Augmentation Using Convolutional Neural Network for Batik Classification. *2020 8th International Conference on Cyber and IT Service Management, CITSM 2020*.  
<https://doi.org/10.1109/CITSM50537.2020.9268890>
- Lasniari, S., Jasril, J., Sanjaya, S., Yanto, F., & Affandes, M. (2022). Klasifikasi Citra Daging Babi dan Daging Sapi Menggunakan Deep Learning Arsitektur ResNet-50 dengan Augmentasi Citra. *Jurnal Sistem Komputer Dan Informatika (JSON)*, 3(4), 450. <https://doi.org/10.30865/json.v3i4.4167>
- Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy assessment in

convolutional neural network-based deep learning remote sensing studies— part 2: Recommendations and best practices. *Remote Sensing*, 13(13). <https://doi.org/10.3390/rs13132591>

Mustamin, N. F., Sari, Y., & Khatimi, H. (2021). Klasifikasi Kualitas Kayu Kelapa Menggunakan Arsitektur Cnn. *Klik - Kumpulan Jurnal Ilmu Komputer*, 8(1), 49. <https://doi.org/10.20527/klik.v8i1.370>

Nufus, N., Ariffin, D. M., Satyawan, A. S., Nugraha, R. A. S., Asyasyakur, M. I., Marlina, N. N. A., Parangin, C. H., & Ema, E. (2021). Sistem Pendeteksi Pejalan Kaki Di Lingkungan Terbatas Berbasis SSD MobileNet V2 Dengan Menggunakan Gambar 360° Ternormalisasi. *Prosiding Seminar Nasional Sains Teknologi Dan Inovasi Indonesia (SENASTINDO)*, 3(November), 123–134. <https://doi.org/10.54706/senastindo.v3.2021.123>

Patil, M. S., Chickerur, S., Abhimalya, C., Naik, A., Kumari, N., & Maurya, S. (2023). Effective Deep Learning Data Augmentation Techniques for Diabetic Retinopathy Classification. *Procedia Computer Science*, 218, 1156–1165. <https://doi.org/10.1016/j.procs.2023.01.094>

Rasyidi, M. A., & Bariyah, T. (2020). Batik pattern recognition using convolutional neural network. *Bulletin of Electrical Engineering and Informatics*, 9(4), 1430–1437. <https://doi.org/10.11591/eei.v9i4.2385>

Ridho Aji Pangestu, Basuki Rahmat, & Fetty Tri Anggraeny. (2020). Implementasi Algoritma Cnn Untuk Klasifikasi Citra Lahan Dan Perhitungan Luas. *Jurnal Informatika Dan Sistem Informasi (JIFoSI)*, 1(1), 166–174.

Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtjas, H. P. A., Yustanti, W., & Prihanto, A. (2021). Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer

- Adam. *Journal of Information Engineering and Educational Technology*, 5(2), 44–48. <https://doi.org/10.26740/jieet.v5n2.p44-48>
- Rusitati, E. L., Suroso, E., Warsono, W., Junaidi, J., Lumbanraja, F. R., & Priyambodo, P. (2019). Sinergitas Peningkatan Ekonomi Kerajinan Batik Lampung, Eksplorasi Budaya Dan Edukasi Konservasi: Andanan Batik Tulis, Negeri Sakti, Pesawaran, Lampung. *Sakai Sambayan Jurnal Pengabdian Kepada Masyarakat*, 3(2), 60. <https://doi.org/10.23960/jss.v3i2.146>
- Sanjaya, J., & Ayub, M. (2020). Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(2), 311–323. <https://doi.org/10.28932/jutisi.v6i2.2688>
- Saputra, R. A., Wasuyanti, S., Supriyatna, A., & Saefudin, D. F. (2021). Penerapan Algoritma Convolutional Neural Network Dan Arsitektur MobileNet Pada Aplikasi Deteksi Penyakit Daun Padi. *Swabumi*, 9(2), 184–188. <https://doi.org/10.31294/swabumi.v9i2.11678>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Suartika E. P, I Wayan, Wijaya Arya Yudhi, S. R. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101. *Jurnal Teknik ITS*, 5(1), 76. <http://repository.its.ac.id/48842/>
- Tumewu, S. F., Setiabud, D. H., & Sugiarto, I. (2020). Klasifikasi Motif Batik menggunakan metode Deep Convolutional Neural Network dengan Data Augmentation. *Jurnal Infra*, 8(2), 189–194.
- Wang, W., Li, Y., Zou, T., Wang, X., You, J., & Luo, Y. (2020). A novel image

classification approach via dense-mobilenet models. *Mobile Information Systems*, 2020. <https://doi.org/10.1155/2020/7602384>

Wibawa, M. S. (2017). Pengaruh Fungsi Aktivasi, Optimisasi dan Jumlah Epoch Terhadap Performa Jaringan Saraf Tiruan. *Jurnal Sistem Dan Informatika (JSI)*, 11(January 2017), 167–174.  
<https://doi.org/10.13140/RG.2.2.21139.94241>

Wulandari, A. (2022). *Batik Nusantara: Makna Filosofis, Cara Pembuatan, dan Industri Batik*. Penerbit Andi.  
<https://books.google.co.id/books?id=mm13EAAAQBAJ>

Zeithml, O. R. (2021). International Journal of Advanced Research in Artificial Intelligence. *Angewandte Chemie International Edition*, 6(11), 951–952., 2013–2015.

Sapuan. (2023, 09 Mei). Wawancara pribadi.

Lee, Wei-Meng. (2022). Image Data Augmentation for Deep Learning. *Towards Data Science*. <https://towardsdatascience.com/image-data-augmentation-for-deep-learning-77a87fabd2bf#:~:text=Types%20of%20Image%20Data%20Augmentation,%2C%20and%20Zoom%20In%2FOut>

Sena, Samuel. (2017). Pengenalan Deep Learning Part 7 : Convolutional Neural Network (CNN). *Medium*. <https://medium.com/@samuelsena/pengenalan-deep-learning-part-7-convolutional-neural-network-cnn-b003b477dc94>