

**PERBANDINGAN KINERJA ARSITEKTUR CONVOLUTIONAL NEURAL
NETWORK (CNN) ALEXNET DAN EFFICIENTNET UNTUK
IDENTIFIKASI CITRA BATIK LAMPUNG**

(Skripsi)

Oleh

**ABBIE SYEH NAHRI
NPM 1917051018**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

**PERBANDINGAN KINERJA ARSITEKTUR CONVOLUTIONAL NEURAL
NETWORK (CNN) ALEXNET DAN EFFICIENTNET UNTUK
IDENTIFIKASI CITRA BATIK LAMPUNG**

Oleh

ABBIE SYEH NAHRI

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
2024**

ABSTRAK

PERBANDINGAN KINERJA ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK (CNN) ALEXNET DAN EFFICIENTNET UNTUK IDENTIFIKASI CITRA BATIK LAMPUNG

Oleh

ABBIE SYEH NAHRI

Motif batik mencerminkan filosofi dan budaya dari setiap daerah, termasuk Batik Lampung dengan berbagai coraknya yang khas. Motif pada batik Lampung mencakup berbagai hal kehidupan disekitar. Motif batik Lampung yang beragam dapat dikenali dari pola-pola khasnya. Namun, masih sulit membedakan batik Lampung hanya dengan melihat warna, corak, dan teksturnya menggunakan mata manusia karena batik lampung bersifat identitas suatu suku dan daerah sehingga motifnya tidak mudah untuk dibedakan.

Pengenalan terhadap motif batik Lampung sangat penting agar orang awam dapat dengan mudah mengetahui jenis-jenis batik Lampung. Oleh karena itu, diperlukan teknologi untuk mempermudah proses identifikasi.

Teknologi computer vision dalam deep learning, yang dikenal sebagai Convolutional Neural Network (CNN) dengan arsitektur yang dipakai AlexNet dan EfficientNet-B4 untuk mengidentifikasi citra dan mempelajari pola citra dengan jumlah yang banyak. Dataset yang digunakan sebanyak 1000 citra dari 10 kelas motif batik lampung yang telah diagumentasi. Teknik Augmentasi yang digunakan yaitu rotate, shift, dan zoom. Hasil akurasi sebesar 95,33% untuk arsitektur AlexNet dan 98,00% arsitektur EfficientNet-B4. Meskipun masih ditemukan beberapa kesalahan dalam klasifikasi, disebabkan oleh kesamaan pola dan kesamaan posisi gambar

Kata kunci: Batik Lampung, Convolutional Neural Network, AlexNet, EfficientNet

ABSTRACT

COMPARISON OF PERFORMANCE OF CONVOLUTIONAL NEURAL NETWORK (CNN) ALEXNET AND EFFICIENTNET ARCHITECTURES FOR LAMPUNG BATIK IMAGE IDENTIFICATION

By

ABBIE SYEH NAHRI

Batik motifs reflect the philosophy and culture of each region, including Batik Lampung, which has various distinctive patterns. The motifs on Batik Lampung cover multiple aspects of local life. Various Batik Lampung motifs can be recognized from their unique patterns, but distinguishing them by looking at the colour, pattern, and texture is still being determined by the human eye. Because Batik Lampung is the identity of a tribe and region, the motifs are not easy to distinguish.

Introducing Batik Lampung motifs is critical so that ordinary people can learn about the types of Batik Lampung quickly. Therefore, technology is needed to simplify the identification process.

Computer vision technology in deep learning, such as Convolutional Neural Network (CNN) with the AlexNet and EfficientNet-B4 architectures, is used to identify images and learn image patterns in large numbers. The dataset is 1000 images from 10 classes of Batik Lampung motifs, which have been augmented using rotate, shift and zoom techniques. The accuracy results reached 95.33% for the AlexNet architecture and 98.00% for the EfficientNet-B4 architecture. Although there are still some errors in classification, this is due to the similarity of image patterns and positions.

Keywords: Lampung Batik, Convolutionl Neural Network, AlexNet, EfficientNet

Judul Skripsi

**: PERBANDINGAN KINERJA ARSITEKTUR
CONVOLUTIONAL NEURAL NETWORK
(CNN) ALEXNET DAN EFFICIENTNET
UNTUK IDENTIFIKASI CITRA BATIK
LAMPUNG**

Nama Mahasiswa

: Abbie Syeh Nahri

Nomor Pokok Mahasiswa

: 1917051018

Program Studi

: S1 Ilmu Komputer

Jurusan

: Ilmu Komputer

Fakultas

: Matematika dan Ilmu Pengetahuan Alam



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

Dwi Sakethi, S.Si., M.Kom.
NIP. 19680617 199802 1 001

MENGESAHKAN

1. Tim Pengaji

Ketua

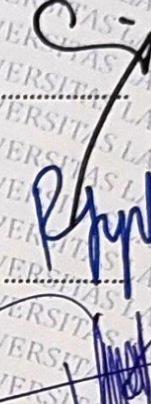
Sekretaris

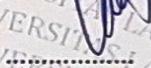
Pengaji

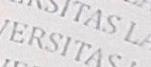
: Rico Andrian, S.Si., M.Kom.

: Rahman Taufik, S.Pd, M. Kom

: Didik Kurniawan, S.Si., M.T.



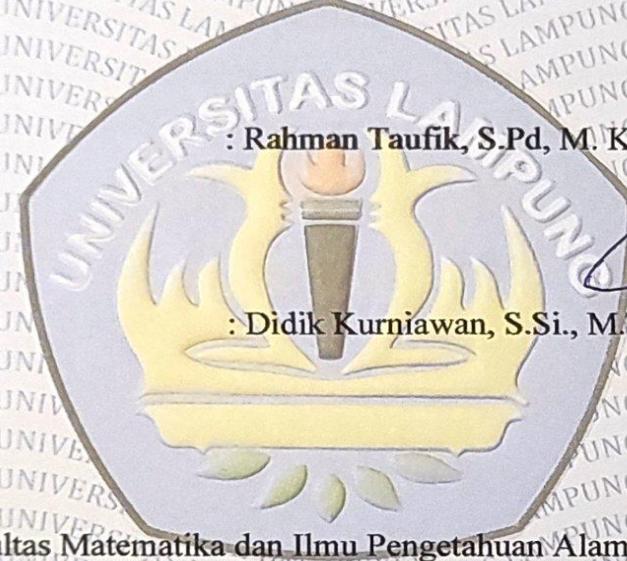






Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 197110012005011002



Tanggal Lulus Ujian Skripsi: 5 Agustus 2024

PERNYATAAN

Saya yang bertanda tangan di bawah, menyatakan bahwa skripsi saya yang berjudul **“Perbandingan Kinerja Arsitektur Convolutional Neural Network (CNN) Alexnet dan Efficientnet untuk 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, 9 Desember 2024



Abbie Syeh Nahri
NPM 1917051018

RIWAYAT HIDUP



Lahir pada 7 Mei 2001. Anak pertama dari Setiyono dan Tri Winarsih, menyelesaikan pendidikan sekolah dasar pada tahun 2013 di SDN 01 Bumi Dipasena Sejahtera. Menyelesaikan sekolah menengah pertama di SMPN 1 Rawajitu Timur pada tahun 2016. Menyelesaikan sekolah menengah atas di

SMAN 1 Trimurjo pada tahun 2019. Pada tahun 2019, terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Universitas Lampung melalui jalur SNMPTN. Kegiatan yang dilakukan selama menjadi mahasiswa sebagai berikut.

1. Menjadi anggota divisi Keilmuan Himpunan Mahasiswa Ilmu Komputer periode 2020.
2. Menjadi anggota BEM FMIPA Unila bidang PSDM periode 2021
3. Melaksanakan Kerja Praktik pada bulan Januari 2022 di Badan Pengelola Keuangan dan Aset Daerah.
4. Melaksanakan KKN di Desa Sukorahayu Lampung Timur, Lampung pada tahun 2022.

MOTTO

“Sungguh, Kami benar-benar telah menciptakan manusia dalam bentuk yang sebaik-baiknya.”

(QS At-Tin: 4)

“Karena sesungguhnya sesudah kesulitan itu ada kemudahan, sesungguhnya sesudah kesulitan itu ada kemudahan. “

(Q.S Al-Insyirah: 5-6)

“Pengetahuan yang baik adalah yang memberikan manfaat, bukan hanya diingat.”

(Imam Syafi'i)

“Keberhasilan adalah perjalanan panjang dari satu kegagalan ke kegagalan berikutnya tanpa kehilangan semangat.”

(Winston Churchill)

PERSEMBAHAN

Puji dan syukur kehadirat Allah SWT karena atas berkat dan rahmat serta karunia-Nya sehingga saya dapat menyelesaikan skripsi ini dengan baik.

Shalawat serta salam selalu saya sanjung agungkan kepada Nabi Muhammad SAW yang telah membawa umat manusia menuju zaman yang terang benderang ini dan syafaatnya senantiasa dinantikan di yaumil akhir kelak.

Aku persembahkan karya ini kepada:

Kedua Orang Tuaku Tersayang

Sebagai tanda terimakasihku kepada ayah dan ibuku tercinta dan tersayang. Terima kasih telah mendidik dan membesarkanku dengan penuh kasih sayang. Terima kasih selalu mendukung dan mendo'akanku yang terbaik. Terima kasih atas semua pengorbanan, perjuangan kalian yang tak akan mungkin bisa terbalaskan. Terima Kasih Ayah dan Ibu.

Seluruh Keluarga Besar Ilmu Komputer 2019

Jurusan Ilmu Komputer

Fakultas Matematika dan Ilmu Pengetahuan Alam

Universitas Lampung

SAWACANA

Puji syukur penulis ucapkan atas karunia dan kesempatan yang Allah SWT berikan hingga akhirnya dapat menyelesaikan skripsi yang berjudul “Perbandingan Kinerja Arsitektur Convolutional Neural Network (CNN) *Alexnet* dan *Efficientnet* untuk Identifikasi Citra Batik Lampung”. Tidak lupa sholawat serta salam kepada Nabi Muhammad SAW, semoga memberikan syafaat kepada umat-Nya di hari kiamat nanti. Berhasilnya penelitian dan penulisan skripsi ini tidak hanya dilakukan oleh penulis sendiri namun adanya kontribusi beberapa pihak yang turut menyukseskan dan membuat hasil karya ini menjadi lebih baik. Ucapan terima kasih penulis sampaikan kepada pihak-pihak yang telah ikut serta membantu penulis, diantaranya:

1. Allah S.W.T. yang menjadi sumber kekuatan dan kecerdasan, yang selalu memberikan petunjuk selama penulis menyelesaikan skripsi.
2. Kedua orang tua, Setiyono dan Tri Winarsih serta kakak, adik dan keluarga saya yang selalu mendo’akan, menyemangati, serta mendukung, itu semua telah menjadi pendorong utama kesuksesan saya. Semoga apa yang saya capai dapat menjadi sumber keberkahan bagi kita semua.
3. Bapak Rico Andrian, S.Si., M.Kom. selaku Dosen Pembimbing yang telah memberikan ilmu serta masukannya dalam pelaksanaan penelitian dan penulisan skripsi.
4. Bapak Rahman Taufik, S.Pd, M. Kom. selaku Dosen Pembimbing II atas segala ilmu, saran dan bimbingannya selama pelaksanaan penelitian.
5. Bapak Didik Kurniawan, S.Si., M.T. selaku Dosen Penguji yang telah memberikan masukan sehingga penulisan skripsi ini dapat lebih baik.
6. Ibu Yunda Heningtyas, S.Kom., M.Kom. selaku dosen pembimbing akademik atas masukan dan bimbingan selama perkuliahan.

7. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam.
8. Bapak Mulyono, S.Si., M.Si., Ph.D selaku Wakil Dekan Bidang Akademik dan Kerja Sama FMIPA Universitas Lampung.
9. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer Universitas Lampung.
10. Ibu Anie Rose Irawati, S.T., M.Cs. selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
11. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan ilmu dan pengalaman dalam hidup untuk menjadi lebih baik.
12. Ibu Ade Nora Maela, dan Mas Ardi Nofalian yang telah membantu segala urusan administrasi penulis di Jurusan Ilmu Komputer.
13. Diffa Addien Aziz, Fikri Aslam Taufiqurahman, Hans Christian Herwanto, selaku rekan seperjuangan dalam proses pembuatan skripsi.
14. Hendri Kurniawan, Nanda Bagus Pratama, Gladie Thoriqudin, Ale Habsi, Arrozi Irfan selaku rekan yang telah memberi dukungan moral dan materil yang sangat berharga.
15. Widya Putri Pramudi selaku pasangan yang telah mendampingi dan memberikan dukungan yang berharga.
16. Teman-teman Jurusan Ilmu Komputer Universitas Lampung angkatan 2019 yang senantiasa memberikan dukungan dan telah berjuang bersama menjalankan studi perkuliahan.

Bandar Lampung, 9 Desember 2024



Abbie Syeh Nahri
NPM 1917051018

DAFTAR ISI

DAFTAR ISI	i
DAFTAR TABEL	iii
DAFTAR GAMBAR	iv
I. PENDAHULUAN.....	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
II. TINJAUAN PUSTAKA	7
2.1 Batik.....	7
2.2 Batik Lampung	7
2.3 <i>Supervised Learning</i> dan <i>Unsupervised Learning</i>	12
2.4 <i>Deep learning</i>	13
2.5 <i>Convolutional Neural Network</i>	14
2.6 <i>AlexNet</i>	18
2.7 <i>EfficientNet</i>	19
2.8 Augmentasi Data	19
2.9 <i>Hyperparameter</i>	21
2.10 <i>Overfitting</i>	23

2.11	<i>Confusion matrix</i>	23
III.	METODOLOGI PENELITIAN	26
3.1	Waktu dan Tempat.....	26
3.2	Bahan dan Alat.....	27
3.3	Metode Penelitian	28
IV.	HASIL DAN PEMBAHASAN	32
4.1	Pengumpulan dan Pelabelan <i>Dataset</i>	32
4.2	Augmentasi Data	33
4.3	Pembagian Data.....	33
4.4	Metode Klasifikasi Convolutional Neural Network (CNN).....	34
4.5	Arsitektur <i>AlexNet</i>	38
4.6	Arsitektur <i>EfficientNet-B4</i>	42
4.7	Evaluasi Kinjera Arsitektur <i>AlexNet</i> dan <i>EfficientNet-B4</i>	45
4.8	Evaluasi Kinjera Arsitektur <i>AlexNet</i> dan <i>EfficientNet-B4</i> Menggunakan Dataset Baru.....	47
4.9	Pembahasan	49
V.	KESIMPULAN DAN SARAN.....	56
5.1	Simpulan.....	56
5.2	Saran	56
	DAFTAR PUSTAKA.....	59

DAFTAR TABEL

Tabel 1. <i>Confusion matrix</i>	23
Tabel 2. <i>Ganchart Penelitian</i>	26
Tabel 3. <i>Hyperparameter</i> model	30
Tabel 4. <i>Dataset</i> Batik Lampung.....	32
Tabel 5. Augmentasi <i>Dataset</i> Batik Lampung	33
Tabel 6. Hasil akurasi <i>data test</i> arsitektur <i>AlexNet</i>	46
Tabel 7. Hasil akurasi data test arsitektur <i>EfficientNet-B4</i>	47
Tabel 8. Dataset Baru Batik Lampung	47
Tabel 9. Perbandingan akurasi arsitektur <i>AlexNet</i> dan <i>EfficientNet-B4</i> menggunakan dataset lama dan dataset baru.....	48
Tabel 10. Perbandingan kinerja arsitektur <i>AlexNet</i> dan <i>EfficientNet-B4</i>	49
Tabel 11. <i>Precision, recall, f1-score</i> arsitektur <i>AlexNet</i>	53
Tabel 12. <i>Precision, recall, f1-score</i> arsitektur <i>EfficientNet-B4</i>	56

DAFTAR GAMBAR

Gambar 1 . Batik Lampung (Sapuan, 2023).....	7
Gambar 2 . Batik Sembagi (Sapuan, 2023)	8
Gambar 3. Batik Granitan (Sapuan, 2023)	8
Gambar 4. Batik Jung Agung (Sapuan, 2023).....	9
Gambar 5. Batik Kembang Cengkih (Sapuan, 2023).....	9
Gambar 6. Batik Tambal (Sapuan, 2023).....	10
Gambar 7. Batik Siger Ratu Agung (Sapuan, 2023).	10
Gambar 8. Batik Abstrak (Sapuan, 2023)	11
Gambar 9. Batik Kambil Sicukil (Sapuan, 2023).....	11
Gambar 10. Batik Sekar Jagat (Sapuan, 2023).....	12
Gambar 11. Batik Sinaran (Sapuan, 2023).....	12
Gambar 12. Lapisan <i>Convolutional Neural network</i> (CNN) (Alzubaidi <i>et al.</i> , 2021).	15
Gambar 13. Lapisan di dalam <i>AlexNet</i> (Han <i>et al.</i> , 2017).....	18
Gambar 14. Lapisan di dalam <i>EfficientNet-B4</i> (Shah <i>et al.</i> , 2022)	19
Gambar 15. Augmentasi <i>Rotation</i> (Sentosa <i>et al.</i> , 2022)	20
Gambar 16. Augmentasi <i>shift</i> (Sentosa <i>et al.</i> , 2022).....	21
Gambar 17. Augmentasi <i>zoom</i> (Sentosa <i>et al.</i> , 2022)	21
Gambar 18. Alur Penelitian.	28
Gambar 19. <i>Source code split</i> data pada model.	34
Gambar 20. RGB <i>image</i> Batik Jung Agung.....	35
Gambar 21. Operasi konvolusi.	36
Gambar 22. Proses <i>pooling</i>	37
Gambar 23. <i>Fully-connected Layer</i> (Bakti dan Firdaus, 2023).....	37
Gambar 24. Arsitektur <i>AlexNet</i> (Kholik, 2021)	38

Gambar 25. Alur model arsitektur <i>AlexNet</i> (Ilahiyah dan Nilogiri, 2018).....	39
Gambar 26. Arsitektur <i>EfficientNet-B4</i>	42
Gambar 27. Alur model Arsitektur <i>EfficientNet-B4</i> (Pangkasidhi <i>et al.</i> , 2021) ...	43
Gambar 28. Grafik perbandingan tingkat akurasi arsitektur <i>AlexNet</i>	45
Gambar 29. Grafik perbandingan tingkat akurasi arsitektur <i>EfficientNet-B4</i>	46
Gambar 30. Grafik perbandingan tingkat akurasi arsitektur <i>AlexNet</i> dan <i>EfficientNet-B4</i> dengan dataset baru	49
Gambar 31. MBConv struktur (Ghawi dan Pfeffer, 2019).....	50
Gambar 32. Tabel <i>confusion matrix</i> arsitektur <i>AlexNet</i> dengan <i>Augmentasi</i> data.	52
Gambar 33. Kesalahan prediksi model <i>AlexNet</i>	54
Gambar 34. Kemiripan (a) Batik Sekar Jagat dan (b) Batik Kembang Cengk... <td>54</td>	54
Gambar 35. Kemiripan (a) Batik Tambal dan (b) Batik Kembang Cengkih.....	55
Gambar 36. Tabel <i>confusion matrix</i> arsitektur <i>EfficientNet-B4</i> dengan <i>Augmentasi</i> data.	55
Gambar 37. Kesalahan prediksi model <i>EfficientNet-B4</i>	57
Gambar 38. Kemiripan (a) Batik Kambil Sicukil dan (b) Batik Jung Agung.	57

I. PENDAHULUAN

1.1 Latar Belakang

Bangsa Indonesia memiliki banyak budaya yang sangat bernilai dan terkenal, salah satunya adalah batik. Batik merupakan identitas bangsa Indonesia yang sudah dikenal sebagai warisan budaya nusantara, dengan cara melukis di atas kain menggunakan lilin dan canting sebagai alat pengaplikasiannya yang memiliki nilai seni tinggi (Dewanti, 2021). Batik telah diakui oleh *United Nations Educational, Scientific and Cultural Organisation* (UNESCO) sebagai warisan budaya Indonesia. Motif batik dapat menandakan asal daerah maupun asal keluarga. Motif batik terdapat banyak corak yang menggambarkan filosofi dan budaya dari tiap-tiap daerah, salah satunya adalah Batik Lampung.

Ragam jenis motif batik sudah sangat bervariasi pada zaman sekarang terutama di daerah Lampung. Ragam batik lampung terdapat 3 jenis batik jika ditinjau dari proses pembuatannya yaitu batik tulis, batik cap, dan batik tulis *full* motif lampung. Motif di batik Lampung terdapat motif manusia, fauna, hewan laut, kerbau, gajah, kapal tunggal, kapal multi struktur, kapal konvoi, kapal selunas, rumah, pohon hayat, dan lain sebagai pendukung, seperti motif daun kopi, cengkeh, lada, sirih sebagai motif identitas Lampung (Astawan, 2021). Motif batik lampung yang cukup beragam dapat dikenali jika melihat dari motif pada batik lampung, tetapi masih sulit untuk membedakan dengan melihat warna, corak serta tekstur menggunakan mata manusia. *Bandung Fe Institute* dan *Surya Research International* melalui *Indonesian Archipelago Cultural Initiatives* (IACI) pada tahun 2015 mencatat ada 5.849 motif batik di Indonesia (Ibda, 2021). Identifikasi atau yang biasa disebut pengenalan terhadap motif batik diperlukan,

agar orang awam dapat mengetahui informasi mengenai jenis batik lampung dengan mudah, oleh karena itu untuk memudahkan proses identifikasi diperlukan sebuah teknologi. Teknologi *computer vision* pada *deep learning* atau yang dikenal sebagai *Convolutional Neural network* (CNN) merupakan teknologi yang dapat digunakan untuk proses identifikasi citra pada batik Lampung.

Convolutional Neural network (CNN) berakar dari sejarah *neural network* secara umum. *Neural network* pertama kali dikembangkan pada tahun 1943 oleh Warren McCulloch dan Walter Pitts (Kusnadi dan Pratama, 2017). Model jenis CNN pertama kali diterapkan pada tahun 1988 oleh Yann LeCun, yang mengaplikasikan konsep konvolusi dalam pemrosesan citra namun model tersebut tidak memperoleh perhatian yang luas (LeCun *et al.*, 2015). Alex Krizhevsky, Ilya Sutskever, dan Geoffrey Hinton memenangkan kompetisi *ImageNet* pada tahun 2012 dengan menggunakan model CNN yang mereka sebut *AlexNet* (Srivastava *et al.*, 2014). Model ini membuktikan bahwa CNN mampu mengatasi masalah pengenalan objek dengan tingkat akurasi yang sangat baik dan membantu mempopulerkan penggunaan model ini dalam bidang pengolahan citra.

Deep learning adalah implementasi konsep dasar dari *machine learning* yang menerapkan algoritma ANN dengan lapisan yang lebih banyak, lapisan tersembunyi yang digunakan antara lapisan masukan dan lapisan keluaran, maka jaringan ini dapat dikatakan *deep neural net*. *Convolutional neural network* (CNN) merupakan salah satu metode *deep learning* yang merupakan cabang ilmu dari *machine learning* yang berbasis jaringan saraf tiruan yang melatih atau mengajarkan suatu tindakan yang dianggap masuk akal bagi manusia. Metode *Convolutional Neural network* (CNN) memiliki hasil yang paling signifikan dalam pengenalan citra digital (Liu *et al.*, 2015)

Metode CNN dianggap sebagai model terbaik untuk memecahkan masalah deteksi objek dan pengenalan objek (Jalled dan Voronkov, 2016). *Convolutional Neural network* (CNN) adalah pengembangan dari *Multilayer Perceptron* (MLP) yang digunakan untuk mengolah data dua dimensi. CNN termasuk dalam jenis *Dee*

Neural network karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra (Suartika E. P, I Wayan, Wijaya Arya Yudhi, 2016). CNN memiliki beberapa arsitektur umum yang sering digunakan seperti *LeNet 5*, *AlexNet*, *VGGNet*, *GoogleNet*, *ResNet* (Maulana dan Rochmawati, 2020). Proses utama arsitektur CNN terbagi atas *feature extraction layer* dan *fully-connected layer*. *Feature extraction layer* digunakan untuk mengambil informasi prediktif dalam gambar dan menyimpannya pada *fully-connected layer* yang kemudian digunakan dalam proses klasifikasi objek pada gambar. Arsitektur yang digunakan dalam penelitian ini ialah *AlexNet* dan *EfficientNet*.

AlexNet merupakan arsitektur CNN yang mendapatkan gelar juara pada kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) yang merupakan kompetisi *image classification* dengan skala besar. *AlexNet* merupakan terobosan baru yang menggunakan *ConvsNet* yang dipadukan dengan teknik *dropout regularization* (Irfansyah *et al.*, 2021). Arsitektur lainnya ialah *EfficientNets* salah satu model CNN yang dikembangkan oleh *google* pada tahun 2019, yang dikhususkan untuk masalah pengenalan objek atau klasifikasi gambar. *EfficientNets* saat ini memiliki 8 model, yaitu *EfficientNet-B0* sampai *EfficientNet-B7* dengan tingkat akurasi yang semakin tinggi (Atila *et al.*, 2021).

Penelitian sebelumnya terkait penggunaan arsitektur *AlexNet* yang digunakan untuk klasifikasi jenis batik lamongan. Data citra yang digunakan pada penelitian ini adalah citra batik lamongan dengan jumlah data adalah 790 yang dibagi menjadi data *training* sebanyak 576 dan data *testing* sebanyak 214 dengan data kelas yang berjumlah 3 kategori. Hasil yang didapatkan nilai rata-rata *sensitivity* 97%, *specificity* 99%, akurasi 98%, dan *precision* faktor 97% dengan nilai *epoch* adalah 75. Kesimpulan yang diperoleh adalah 2 kelas mampu dikenali seluruhnya dengan benar, sedangkan untuk 1 kelas lainnya belum mampu dikenali sepenuhnya (Anggraini *et al.*, 2022).

Penelitian sebelumnya terkait penggunaan arsitektur *EfficientNet* yang digunakan untuk klasifikasi motif batik papua. Data citra yang digunakan pada penelitian ini

berjumlah 213 *dataset* dengan komposisi 80% data *training* sebanyak 169 gambar, 10% data validasi sebanyak 22 gambar dan 10% data *testing* sebanyak 22 gambar. Pengujian dilakukan menggunakan 4 kelas *dataset* yaitu Raja Ampat, Cendrawasih, Asmat, dan Tifa Honai. Hasil pengujian memperoleh arsitektur *EfficientNet-B2* dengan *fine tuning* memberikan akurasi 72% dan ditambahkan teknik *Augmentasi* tertinggi dengan menggunakan teknik *ColorJitter* dan *Contrast* dengan hasil 90% (Aras *et al.*, 2022).

Penelitian terkait penggunaan arsitektur model *EfficientNet-B3* untuk klasifikasi tumor otak. *Dataset* yang digunakan berjumlah 2875 gambar dengan 2 kelas. Menghasilkan nilai akurasi tertinggi dengan skenario *learning rate* 0.02 dan neuron pada dense yang berjumlah 256 yang menghasilkan nilai akurasi mencapai 99.7 % dan mendapatkan nilai *F1-score* tertinggi dari seluruh skenario dengan nilai *F1-score* mencapai 99.6%. Arsitektur model *EfficientNet-B3* menunjukkan bahwa semakin besar learning rate maka semakin tinggi tingkat akurasi yang didapatkan (Ramadhani *et al.*, 2021).

Penelitian lainnya menggunakan algoritma *Convolutional Neural network* (CNN) pada citra wayang golek. Penelitian ini mengklasifikasikan citra wayang golek menggunakan metode *Convolutional Neural network* (CNN) dengan 240 data *training* dan 60 data *testing* berjumlah 300 citra data digunakan. Tingkat akurasi *training* dan *testing* dalam melakukan klasifikasi gambar wayang golek sebesar 95% *training* dan 90% *testing* (Nurhikmat, 2018).

Penelitian sebelumnya dalam klasifikasi batik lampung pernah dilakukan dengan *K-Nearest Neighbor* (KNN) menggunakan *Gray Level Co-occurrence Matrix* (GLCM) untuk ekstraksi fitur. Klasifikasi terhadap objek batik lampung menggunakan *K-Nearest Neighbor* (KNN) dibagi menjadi 4 kelas . *Dataset* yang digunakan berjumlah 100 gambar batik lampung dengan 25 gambar pada setiap kelas atau motif batiknya. Tahapan diawali dengan *pre-processing* yaitu memotong (*crop*) objek atau gambar motif lampung, kemudian *grayscale*, dan langkah terakhir mengubah ukuran gambar menjadi 50 x 50 *pixel*. Data dibagi menjadi 2

bagian yaitu data latih dan data uji sebesar 70% dan 30%. Hasil akurasi terbesar didapatkan yaitu 97.96% dengan nilai $k = 7$ pada orientasi sudut 135° (Andrian *et al.*, 2019).

Penelitian ini akan menggunakan *dataset* batik lampung dengan 10 kelas yaitu Siger Ratu Agung, Sembagi, Jung Agung, Kembang Cengkikh, Granitan, Abstrak, Sinaran, Tambal, Kambil Sicukil, dan Sekar jagat. Penelitian ini menggunakan arsitektur *Convolutional Neural network AlexNet* dan *EfficientNet-B4* untuk dilakukan perbandingan dan mengetahui tingkat akurasi yang paling baik terhadap identifikasi citra batik lampung.

1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah bagaimana perbandingan tingkat akurasi identifikasi batik lampung menggunakan arsitektur *convolutional neural network* (CNN) *AlexNet* dan *EfficientNet-B4*.

1.3 Batasan Masalah

Batasan masalah dari penelitian ini menggunakan *dataset* batik lampung dengan 10 kelas yaitu Siger Ratu Agung, Sembagi, Jung Agung, Kembang Cengkikh, Granitan, Abstrak, Sinaran, Tambal, Kambil Sicukil, dan Sekar jagat.

1.4 Tujuan Penelitian

Tujuan dari dilakukannya penelitian ini adalah membandingkan kinerja arsitektur *Convolutional Neural network* (CNN) *AlexNet* dan *EfficientNet-B4* dalam identifikasi citra batik lampung.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini agar dapat digunakan sebagai bahan rujukan dalam penelitian selanjutnya berkaitan tentang identifikasi citra batik dengan menggunakan metode *Convolutional Neural network* (CNN).

II. TINJAUAN PUSTAKA

2.1 Batik

Batik adalah seni tradisional membuat kain dengan menggunakan teknik menuliskan atau melukis pola dengan malam atau lilin pada kain. Proses ini dilakukan sebelum kain diwarnai. Setelah kain diwarnai dan malam dihilangkan, pola yang tertulis dengan malam akan terlihat jelas di atas kain. Batik merupakan warisan budaya Indonesia yang telah diakui oleh UNESCO sebagai warisan budaya tak benda manusia yang memiliki nilai universal pada tahun 2009. Batik juga telah menjadi salah satu kebanggaan Indonesia dan dipakai pada berbagai acara formal maupun informal (Dewanti, 2021).

2.2 Batik Lampung



Gambar 1 . Batik Lampung (Sapuan, 2023).

Batik Lampung memiliki ciri khas pola dan warna yang cerah, serta menggunakan teknik pembuatan batik tulis dan batik cap yang dapat dilihat pada gambar 1.

Motif batik Lampung banyak terinspirasi dari alam dan kebudayaan Lampung, seperti motif tumbuhan, hewan, dan ornamen-ornamen khas Lampung. Batik Lampung juga memiliki keunikan tersendiri dalam teknik pembuatannya yaitu dengan memanfaatkan bahan-bahan alami seperti soga, kunyit, dan kapur sirih dalam proses pencelupan warna yang memberikan hasil akhir yang khas dan unik pada batik Lampung.

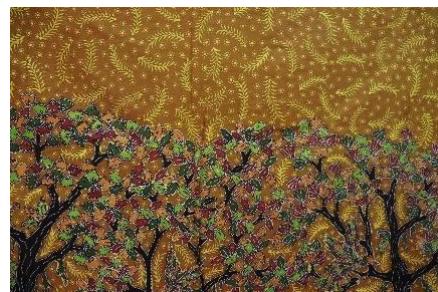
2.2.1 Batik Sembagi



Gambar 2 . Batik Sembagi (Sapuan, 2023).

Batik Sembagi memiliki ciri motif khas kembang dengan isian cengklik (Sapuan, 2023). Citra batik Sembagi dapat dilihat pada gambar 2.

2.2.2 Batik Granitan



Gambar 3. Batik Granitan (Sapuan, 2023).

Gambar 3 adalah batik Granitan tidak memiliki motif khusus, batik granitan adalah teknik melukis batik dengan ciri garik titik-titik disekitar motif batik biasanya berwarna putih (Sapuan, 2023).

2.2.3 Batik Jung Agung



Gambar 4. Batik Jung Agung (Sapuan, 2023).

Batik Jung Agung memiliki ciri motif khas jung atau yang biasa disebut kapal. Batik Jung Agung modifikasi terdapat motif lain sebagai isiannya namun lebih dominan untuk motif jung atau kapal (Sapuan, 2023). Citra batik Jung Agung dapat dilihat pada gambar 4.

2.2.4 Batik Kembang Cengkikh



Gambar 5. Batik Kembang Cengkikh (Sapuan, 2023).

Batik Kembang Cengkikh memiliki motif khas kembang cengkikh. Motif kembang cengkikh terdapat juga pada batik sembagi. Batik Kembang Cengkikh juga dapat dimodifikasi dengan menggunakan isian motif lain (Sapuan, 2023). Citra batik Kembang Cengkikh dapat dilihat pada gambar 5.

2.2.5 Batik Tambal



Gambar 6. Batik Tambal (Sapuan, 2023).

Batik Tambal memiliki ciri khas batik dengan bentuk kotak dengan isian motif lain, seperti siger, jung, dan kembang cengkoh (Sapuan, 2023). Citra batik Tambal dapat dilihat pada gambar 5.

2.2.6 Batik Siger Ratu Agung



Gambar 7. Batik Siger Ratu Agung (Sapuan, 2023).

Batik Siger Ratu Agung memiliki motif identik dengan pengantin tunggal maupun yang berhadapan (Sapuan, 2023). Citra Batik Siger Ratu Agung dapat dilihat pada gambar 7.

2.2.7 Batik Abstrak



Gambar 8. Batik Abstrak (Sapuan, 2023).

Batik Abstrak memiliki ciri khas yaitu batik dengan beberapa motif dalam satu batik. Motif batik abstrak memiliki beberapa isian motif diantaranya isian daun, kembang, segitiga, dan jung (Sapuan, 2023). Citra batik Abstrak dapat dilihat pada gambar 8.

2.2.8 Batik Kambil Sicukil



Gambar 9. Batik Kambil Sicukil (Sapuan, 2023).

Batik Kambil Sicukil memiliki ciri khas motif dengan gambar atau ikon yang ada di dalam segitiga. Motif yang berada di dalam segitiga dapat motif jung, siger, dan manusia (Sapuan, 2023). Citra batik Kambil Sicukil dapat dilihat pada gambar 9.

2.2.9 Batik Sekar Jagat



Gambar 10. Batik Sekar Jagat (Sapuan, 2023).

Batik Sekar Jagat memiliki ciri khas bentuk jajar genjang motif mirip dengan batik kambil sicukil. Batik sekar jagat memiliki isian gambar atau motif lain seperti kembang, jung, hewan, dan siger (Sapuan, 2023). Citra batik Sekar Jagat dapat dilihat pada gambar 10.

2.2.10 Batik Sinaran



Gambar 11. Batik Sinaran (Sapuan, 2023).

Batik Sinaran dinamakan “sinaran” dikarenakan memiliki ciri khas motif garis membentuk kerucut seperti sinar bentuk jajar genjang (Sapuan, 2023).. Citra batik Sinaran dapat dilihat pada gambar 11.

2.3 *Supervised Learning* dan *Unsupervised Learning*

Supervised learning adalah pembelajaran model atau algoritma diberikan data yang sebelumnya telah di berikan label atau anotasi, dimana data pelatihan memiliki pasangan *input* dan *output* yang sesuai. Tujuan dari *supervised learning* adalah

untuk mengajarkan sebuah model untuk memahami hubungan antara *input* dan *output* agar dapat memprediksi data baru atau data yang belum pernah dilihat sebelumnya dengan benar (Zeithml, 2021).

model atau algoritma menggali struktur tanpa diberikan data label atau anotasi disebut *Unsupervised learning*. Model mengidentifikasi kesamaan, perbedaan dalam data tanpa label. Tugas *unsupervised learning* adalah untuk pengelompokan data (*clustering*), reduksi dimensi (mengurangi jumlah fitur dalam data), dan pemodelan distribusi data, sedangkan pemakaian *unsupervised learning* untuk mengelompokan dokumen, analisis data sosial, dan pengekstrakan fitur otomatis. (Zeithml, 2021).

2.4 Deep learning

Deep learning merupakan pengembangan dari teknologi *machine learning*. *Deep learning* mampu bekerja layaknya mata manusia ketika menangkap informasi berupa gambar, suara, gerakan dan bentuk informasi lainnya. Proses kerja *deep learning* menggunakan *artificial neural network* (jaringan saraf buatan) untuk meniru bagaimana manusia berpikir dan belajar. *Artificial Neural network* (ANN) merupakan model matematika yang terinspirasi dari sistem saraf manusia dan dirancang untuk dapat mempelajari pola-pola data (Alzubaidi *et al.*, 2021). Data yang dipelajari *deep learning* semakin banyak membuat *deep learning* lebih akurat dapat mengidentifikasi sebuah objek.

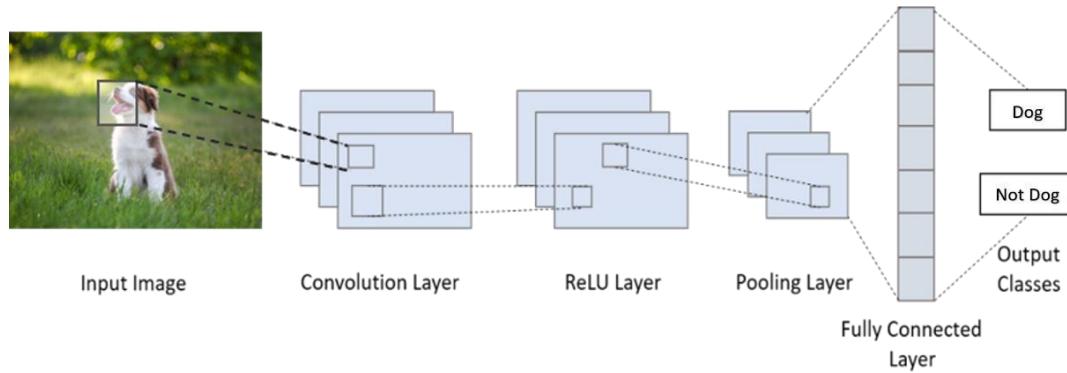
Model *deep learning* dilatih melalui banyak lapisan untuk membaca, menyimpan, memproses, dan mengklasifikasi sebuah masukan, sehingga seringkali kinerja *deep learning* melampaui kinerja manusia. *Deep learning* belajar menggunakan data dan contoh yang sudah ada di dalam komputer, selanjutnya *neural network* akan otomatis mengekstrasi ciri dari data yang kemudian data tersebut diproses agar dapat diklasifikasikan menggunakan algoritma *deep learning*. *Deep learning* sampai saat ini terus berkembang hingga memiliki bermacam-macam algoritma,

diantaranya *Multilayer Perceptron* (MLP), *Convolutional Neural network* (CNN), *Recurrent Neural network* (RNN), *Faster R-CNN*, YOLO, dan lain-lain. Algoritma *deep learning* digunakan untuk mengenali tulisan, suara, dan objek.

2.5 Convolutional Neural Network

Convolutional Neural network (CNN) adalah salah satu jenis arsitektur *neural network* pada *deep learning* yang dirancang khusus untuk memproses data dalam bentuk matriks seperti gambar, video, atau audio. *Convolutional Neural network* pertama kali dikembangkan pada tahun 1988 oleh Yann LeCun. Algoritma ini merupakan pengembangan lebih lanjut dari *Multilayer Perceptron* (MLP) yang memiliki banyak lapisan di dalamnya, untuk bisa memroses nilai-nilai *pixel* pada gambar. CNN hadir dengan perkembangan lebih lanjut dari MLP, CNN dapat mengenali karakter dan gambar dengan kinerja yang lebih baik dibandingkan MLP (Irfansyah *et al.*, 2021).

CNN bekerja dengan adanya lapisan tersembunyi yang berfungsi untuk identifikasi gambar, dan susunan dari *neural network* (jaringan saraf) yang saling terhubung untuk menyatukan ciri dari gambar tersebut. Lapisan pertama pada CNN berfungsi mengidentifikasi fitur visual pada citra seperti garis, tepi, dan tekstur, kemudian *output* dari lapisan pertama akan dijadikan masukan pada lapisan selanjutnya untuk dikenali ciri yang lebih kompleks. Ciri objek yang sulit untuk terdeteksi adalah objek dengan bentuk dan warna yang semakin detail pada lapisan yang dalam.



Gambar 12. Lapisan *Convolutional Neural network* (CNN) (Alzubaidi *et al.*, 2021).

Gambar 12 menunjukkan lapisan *neural network* yang tersusun berfungsi untuk mengamati serta menganalisa objek yang diinputkan. CNN melakukan proses interpretasi lebih baik, akurat, dan cepat dibandingkan pengamatan menggunakan mata manusia yang masih ditemukan kesalahan dalam interpretasi sebuah objek (Lesmana *et al.*, 2022). CNN dalam pemrosesannya semua dilakukan secara otomatis mulai dari pengambilan ciri pada sebuah objek, kemudian pembentukan angka *pixel* dimana nantinya digunakan untuk menyimpan ciri dari objek yang di proses. CNN memiliki dua lapisan yaitu *feature extraction layer* dan *fully-connected layer*.

2.5.1 Feature Extraction Layer

Feature extraction layer (lapisan ekstraksi fitur) berada pada awal arsitektur yang tersusun dari beberapa lapisan dan setiap lapisan tersusun atas neuron yang terkoneksi pada daerah lokal (Ilahiyah dan Nilogiri, 2018). *Feature extraction layer* ialah lapisan di dalam CNN yang bertanggung jawab melakukan pengambilan ciri dari sebuah objek dan menyimpannya dalam nilai-nilai *pixel* yang berbentuk *array*. *Input* gambar terdiri dari nilai *pixel* yang berbentuk *array* multidimensi, dalam pemrosesannya ukuran *array* multidimensi terlalu besar maka diperlukan *filter* yang digunakan untuk mengambil ciri-ciri utama dari sebuah *input* gambar.

Feature extraction layer menyediakan lapisan yang terdapat *filter* yang akan melalui proses perhitungan menggunakan perkalian matriks antara gambar dengan

filternya yang bertujuan untuk mengambil fitur-fitur penting dari data *input* dan mengubahnya menjadi representasi yang lebih sederhana tanpa menghilangkan ciri yang penting dari objek gambar. Proses ekstraksi fitur biasanya melibatkan berbagai operasi seperti *convolution layer*, dan *pooling layer* (Bodapati dan Veeranjaneyulu, 2019).

2.5.1.1 Convolution Layer

Convolutional layer atau biasa disebut lapisan konvolusi adalah salah satu jenis lapisan yang digunakan untuk melakukan ekstraksi fitur dari data *input* berupa citra atau gambar seperti tepi, sudut, dan pola visual lainnya (Setiawan dan Avianto, 2020). Konvolusi didefinisikan sebagai proses menyederhanakan nilai pada citra untuk memperoleh suatu *pixel* didasarkan pada nilai *pixel* itu sendiri melalui perkalian antara matrix masukan dengan *filter*. *Input* gambar memiliki nilai *pixel* berbentuk *array* multidimensi yang akan disederhanakan oleh *filter* tanpa menghilangkan ciri utama objek. Hasil operasi ini menghasilkan *output* sebagai *feature map* atau peta ciri dari masukan citra (Ilahiyah dan Nilogiri, 2018).

2.5.1.2 Pooling Layer

Pooling layer atau lapisan *pooling* adalah salah satu jenis lapisan yang digunakan untuk mengurangi dimensi dari fitur yang diekstraksi oleh lapisan sebelumnya. Lapisan *pooling* befungsi untuk mengurangi ukuran citra atau representasi fitur untuk mempercepat proses komputasi dan mengurangi *overfitting* (Ilahiyah dan Nilogiri, 2018). Proses pada *layer* ini akan mengambil nilai terbesar (*max pooling*) dan nilai rata-rata (*average pooling*) *pixel* dari *feature map* yang dihasilkan oleh *layer* konvolusi. *Max pooling* sering digunakan untuk mengekstraksi ciri utama dari data masukan, misalnya objek yang memiliki ukuran yang berbeda-beda pada gambar. *Average pooling* sering digunakan untuk meratakan nilai-nilai yang berbeda pada data masukan, misalnya pada data dengan variasi nilai yang besar, sehingga menghasilkan nilai representatif yang lebih stabil.

2.5.2 Fully-connected Layer

Fully-connected layer ialah lapisan dalam CNN yang digunakan untuk tahapan klasifikasi objek gambar. *Fully-connected layer* digunakan pada lapisan akhir dari jaringan saraf untuk menghasilkan *output* akhir dari klasifikasi terhadap kelas objek. Proses pengeluaran pada *fully-connected layer* dihitung dengan melakukan perkalian matriks antara vektor *input* dengan matriks bobot. *Input* pada *fully-connected layer* berupa vektor atau satu dimensi, dimana sebelum masuk tahap klasifikasi harus melalui perataan bentuk atau *flatten* (Ilahiyah dan Nilogiri, 2018). *Fully-connected layer* terdiri atas dua parameter yaitu *weights* (bobot) dan bias, dengan neuron untuk setiap parameter yang terhubung dengan lapisan sebelumnya.

a. Rectified Linear Unit (*ReLU*) Activation

Aktivasi *ReLU* (*Rectified Linear Unit*) merupakan fungsi aktivasi yang mengajarkan fungsi *non-linear* dalam *convolutional layer*. *ReLU* digunakan pada lapisan *convolutional* (konvolusi) dan *pooling* tergantung pada kebutuhan dan arsitektur jaringan yang digunakan. Lapisan *convolutional* biasanya menggunakan *ReLU* sebagai fungsi aktivasi setelah operasi konvolusi untuk menambahkan *non-lineartas* pada *output* konvolusi, sehingga memungkinkan jaringan untuk mempelajari pola-pola yang lebih kompleks dan lebih adaptif.

Fungsi aktivasi *ReLU* juga membantu mengatasi masalah *vanishing gradient* dan mempercepat proses pelatihan. Lapisan *pooling* *ReLU* digunakan sebagai fungsi aktivasi untuk membantu mempercepat proses *pooling* dan mengurangi kompleksitas jaringan. *ReLU* pada lapisan *pooling* juga membantu dalam pengurangan *overfitting* dan meningkatkan generalisasi pada model. Proses *ReLU* akan mengembalikan nilai negatif menjadi 0 dan mengembalikan nilai positif menjadi nilai itu sendiri. Fungsi yang digunakan dalam *ReLU* adalah $f(x) = \max(0, x)$ dimana fungsi ini melakukan thresholding menggunakan nilai nol pada nilai piksel pada *input* citra (Ilahiyah dan Nilogiri, 2018).

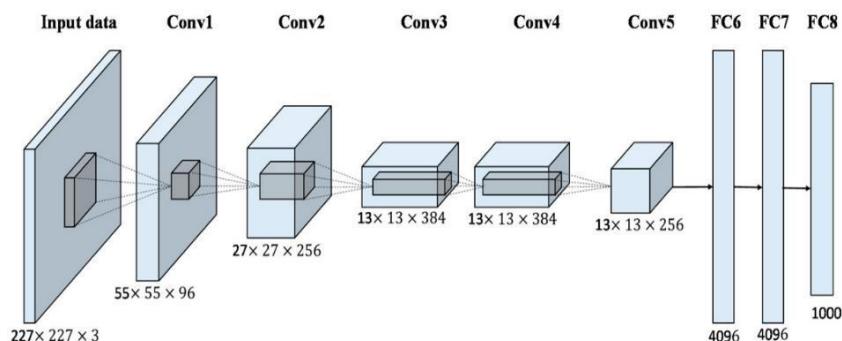
b. Softmax activation

Softmax activation adalah fungsi matematis yang mengonversi *input* vektor (x) menjadi *output* vektor dalam bentuk distribusi probabilitas. Aktivasi *Softmax*

adalah bentuk lain dari algoritma *Logistic Regression* yang dapat digunakan untuk menghasilkan probabilitas untuk setiap kelas (Ilahiyah dan Nilogiri, 2018). *Softmax* digunakan untuk klasifikasi yang terdiri lebih dari dua kelas atau biasa disebut *multiclass classification*.

2.6 AlexNet

AlexNet merupakan arsitektur CNN yang mendapatkan gelar juara pada kompetisi *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) yang merupakan kompetisi *image classification* dengan skala besar. *AlexNet* merupakan terobosan baru yang menggunakan *ConvsNet* yang dipadukan dengan teknik *dropout regularization* (Irfansyah *et al.*, 2021). Arsitektur *AlexNet* terdiri dari 8 *layer* utama, dengan 5 *layer* konvolusi dan 3 *layer* *fully connected*. Arsitektur ini juga menggunakan *convolution layer*, *pooling*, *dropout*, *activation ReLu*, *fully-connected layer*. Arsitektur ini cukup mirip dengan *LeNet* hanya saja pada *AlexNet* memiliki convolution *layer* lebih banyak dan parameter latih model yang lebih besar dibandingkan *LeNet*. Lapisan di dalam *AlexNet* dapat dilihat pada Gambar 13.

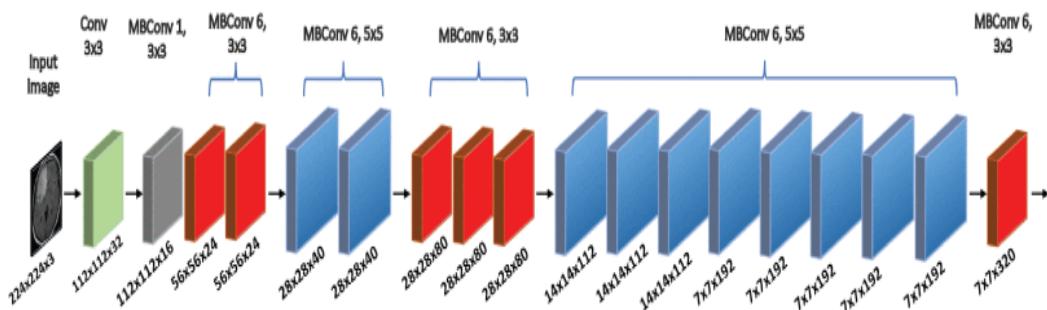


Gambar 13. Lapisan di dalam *AlexNet* (Han *et al.*, 2017).

2.7 EfficientNet

EfficientNet adalah arsitektur jaringan saraf tiruan (*neural network*) yang dikembangkan oleh Mingxing Tan dan Quoc V. Le pada tahun 2019 (Azahro Choirunisa *et al.*, 2021). Arsitektur ini dibentuk lebih efisien dalam penggunaan sumber daya komputasi dan memori, namun tetap mencapai tingkat akurasi yang tinggi dalam tugas-tugas pengolahan citra seperti klasifikasi gambar dan deteksi objek. *EfficientNet* mengadaptasi *MobileNetV2* dan *MnasNet* dengan menggunakan blok MBCConv (*Mobile Inverted Bottleneck Convolution*) yang merupakan blok *inverted residuals structure* yang terdapat pada arsitektur *MobileNetV2* untuk digunakan sebagai lapisannya (Azahro Choirunisa *et al.*, 2021).

EfficientNet-B4 terdiri dari ratusan atau ribuan *layer convolutional neural network* (CNN) yang terorganisir secara hierarkis untuk setiap variannya. Model *EfficientNet-B4* mendapatkan akurasi yang besar dan juga lebih baik dalam efisiensi dibandingkan dengan CNN, model ini juga mengurangi ukuran parameter latih (Tan dan Le, 2019). Lapisan *EfficientNet-B4* dapat dilihat pada Gambar 14.



Gambar 14. Lapisan di dalam *EfficientNet-B4* (Shah *et al.*, 2022).

2.8 Augmentasi Data

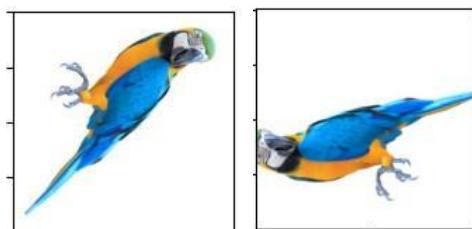
Augmentasi merupakan solusi yang digunakan untuk mengurangi *overfitting* yaitu dimana sebuah model pembelajaran mesin terlalu teliti dalam menangkap detail-detail dari data pelatihan (Ashiquzzaman *et al.*, 2017). Augmentasi data adalah cara

untuk menghasilkan variasi baru dari *dataset* asli. *Dataset* yang asli diperbanyak dengan menggunakan beberapa teknik yang nantinya akan menghasilkan beberapa data dari data asli yang memiliki bentuk, posisi, atau warna yang berbeda dari *dataset* aslinya tanpa merubah label pada data tersebut (Fadillah *et al.*, 2021).

Teknik dalam augmentasi ada rotasi, pemangkasan, pergeseran, warna, kecerahan, dengan menggunakan beberapa teknik dapat menciptakan variasi baru tanpa harus mengumpulkan sampel data tambahan. Augmentasi data juga dapat membantu model untuk generalisasi dengan lebih baik dengan menggunakan teknik yang efisien, sambil tetap mempertahankan label yang sama pada setiap bagian data yang dihasilkan (Sanjaya & Ayub, 2020).

2.8.1 *Rotation*

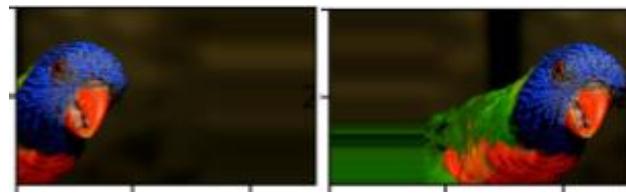
Augmentasi rotasi merupakan teknik augmentasi dengan cara memutar gambar dengan sudut yang ditetapkan. Teknik augmentasi ini bertujuan untuk menghasilkan variasi data yang digunakan untuk melatih model dan meningkatkan kinerja model dalam pengenalan objek atau pengolahan citra (Shorten dan Khoshgoftaar, 2019). Augmentasi *rotation* dapat dilihat pada gambar 15.



Gambar 15. Augmentasi *Rotation* (Sentosa *et al.*, 2022).

2.8.2 *Shift*

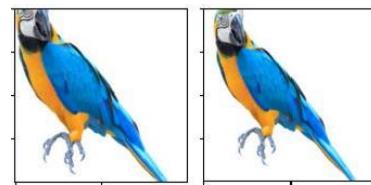
Augmentasi shift merupakan teknik pengolahan citra dengan melakukan pergeseran gambar dalam berbagai arah, baik horizontal maupun vertical. teknik augmentasi *shift* membantu meningkatkan ketahanan model terhadap variasi posisi objek dalam gambar dengan tetap menjaga dimensi gambar tetap sama (Shorten dan Khoshgoftaar, 2019). Augmentasi *shift* dapat dilihat pada gambar 16.



Gambar 16. Augmentasi *shift* (Sentosa *et al.*, 2022).

2.8.3 *Zoom*

Pembesaran atau perkecilan gambar adalah teknik pengolahan citra yang digunakan untuk mengubah ukuran suatu gambar. Teknik augmentasi ini digunakan untuk memodifikasi ukuran objek tanpa mengubah proporsi atau aspek penting lainnya (Lasniari *et al.*, 2022). Augmentasi *zoom* dapat dilihat pada gambar 17.



Gambar 17. Augmentasi *zoom* (Sentosa *et al.*, 2022).

2.9 *Hyperparameter*

Hyperparameter merupakan jenis konfigurasi terhadap sebuah model sebelum proses *training* data. Model *hyperparameter* adalah pengaturan yang nilainya tidak bisa ditebak hanya dari melihat data, nilai tidak bisa dimunculkan secara otomatis namun ditentukan secara manual sebelum model dilatih (Afaq dan Rao, 2020). Parameter akan muncul secara otomatis pada proses *training* sehingga tidak dapat ditentukan secara manual nilainya. *Hyperparameter* terlebih dulu diatur sebelum proses *training* agar dapat menentukan kemunculan nilai-nilai parameter yang digunakan ketika proses *training* untuk memprediksi data dengan baik.

Hyperparameter yang paling sering digunakan dalam model CNN yaitu, *learning-rate*, *batch-size*, *epoch*, dan *optimizer* (Ghawi dan Pfeffer, 2019).

2.9.1 Learning-rate

Learning-rate digunakan pada proses *training* berjalan untuk menghitung nilai koreksi bobot (Rochmawati *et al.*, 2021). *Learning-rate* mengontrol seberapa besar pengaruh dari setiap update parameter terhadap keseluruhan model. *Learning-rate* mengacu kepada ukuran yang tepat untuk mencapai hasil yang baik dalam proses *training*.

2.9.2 Batch-size

Batch-size merupakan pengambilan sample dari data *training* yang kemudian dibentuk menjadi *batch*. *Batch-size* adalah jumlah sampel data yang diproses pada satu kali iterasi selama proses pelatihan model pada algoritma. Iterasi adalah pembacaan data secara *forward* (ke depan) dan *backward* (ke belakang) (Rochmawati *et al.*, 2021). *Dataset* pelatihan akan dibagi menjadi beberapa *batch* atau subset kecil agar dapat diolah dengan lebih efisien pada memori komputer.

2.9.3 Epoch

Salah satu parameter yang mempengaruhi performa sebuah model CNN adalah jumlah *epoch*. *Epoch* adalah nilai yang menentukan berapa banyak proses *training* dilakukan. *Epoch* itu sendiri adalah satu siklus atau putaran algoritma machine learning belajar dari jumlah *dataset training*, sedangkan satu *epoch* adalah ketika seluruh data *training* selesai dipelajari oleh model (Husen *et al.*, 2022).

2.9.4 Optimizer Adam

Adam adalah singkatan dari *Adaptive Moment Estimation* *optimizer* ini menghitung estimasi adaptif dari momen pertama dan kedua dari *gradient*. *Optimizer* ini dapat bekerja dengan baik pada *dataset* besar dan kompleks dengan banyak parameter.

2.10 *Overfitting*

Overfitting merujuk pada keadaan dalam machine learning dan statistik di mana sebuah model pembelajaran mesin terlalu teliti dalam menangkap detail-detail dari data pelatihan. Model dapat menciptakan representasi yang terlalu khusus atau tidak umum yang tidak mampu melakukan generalisasi dengan baik pada data yang belum pernah dilihat sebelumnya. *Overfitting* merupakan salah satu tantangan utama dalam *machine learning* yang dapat mengakibatkan kinerja yang buruk pada data yang berbeda atau data uji yang tidak terlihat sebelumnya (Ashiquzzaman *et al.*, 2017).

2.11 *Confusion matrix*

Confusion matrix adalah sebuah tabel atau matriks yang digunakan untuk mengevaluasi performa suatu model klasifikasi.. *Confusion matrix* terdiri dari *accuracy*, *F1-score* , *precision* dan *recall*. *Confusion matrix* terdiri dari empat kemungkinan hasil prediksi dari suatu model, yaitu *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN) (Yildirim dan Cinar, 2020). Tabel *confusion matrix* dapat dilihat pada tabel 1.

Tabel 1. *Confusion matrix*

		Predicted Class	
		1 (Positive)	0 (Negative)
Actual Class	1 (Positive)	TP (True Positive)	FN (False Negative)
	0 (Negative)	FP (False Positive)	TN (True Negative)

Keterangan :

- *True Positive* : model dengan benar memprediksi sebuah kelas (*positive*) sebagai kelas yang sebenarnya (*positive*).

- *True Negative* : model dengan benar memprediksi sebuah kelas (*negative*) sebagai kelas lain (*negative*).
- *False Positive* : model salah memprediksi kelas lain (*negative*) sebagai kelas yang sebenarnya (*positive*).
- *False Negative* : model salah memprediksi kelas yang sebenarnya (*positive*) sebagai kelas lain (*negative*).

Perhitungan yang dipakai dalam *confusion matrix* :

- *F1-score*

F1-score dipakai untuk mengukur rata-rata dari *precision* dan *recall*. Indikasi *F1-score* yaitu model klasifikasi memiliki nilai *precision* dan *recall* yang baik. *F1-score* digunakan pada kondisi dimana *dataset* yang digunakan dalam proses *training* model tidak seimbang jumlahnya (Maxwell *et al.*, 2021).

$$F1\text{-score} = \frac{2 \times Precision \times Recall}{Precision + Recall} \times 100\% \quad (1)$$

- *Precision*

Precision digunakan untuk menghitung hasil prediksi yang benar dan yang salah untuk sebuah kelas sebenarnya. *Precision* mengukur akurasi model pada klasifikasi sebuah kelas sebenarnya dan juga pada kelas lain yang teridentifikasi atau terklasifikasi sebagai kelas yang sebenarnya. Prediksi benar (TP) akan memiliki *precision* yang besar sedangkan prediksi salah (FP) akan memiliki *precision* yang kecil untuk sebuah model (Maxwell *et al.*, 2021).

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

- *Accuracy*

Accuracy merupakan penilaian yang menunjukkan performa model ketika mengklasifikasi semua kelas objek. *Accuracy* mengukur seberapa akurat model dalam melakukan prediksi kelas secara keseluruhan (Maxwell *et al.*, 2021).

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

- *Recall*

Recall dipakai mengevaluasi seberapa baik suatu model dapat mengidentifikasi dan mengklasifikasikan citra yang termasuk ke dalam suatu kelas. Hasil dapat berupa kelas yang benar diprediksi menjadi kelas sebenarnya dan kelas yang sebenarnya terprediksi oleh kelas lain. *Recall* mengutamakan tingkat keberhasilan kelas sebenarnya terprediksi sebagai kelas tersebut maupun sebagai kelas lain (Maxwell *et al.*, 2021).

$$\text{Recall} = \frac{TP}{TP+FN} \times 100\% \quad (4)$$

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat

Waktu dan tempat penelitian adalah sebagai berikut :

3.1.1 Waktu Penelitian

Penelitian akan dilakukan dari April tahun ajaran 2022/2023 sampai dengan Juli tahun ajaran 2022/2023. Waktu penelitian akan dijelaskan dengan table *ganchart* seperti dibawah.

Tabel 2. *Ganchart* Penelitian

3.1.2 Tempat Penelitian

Penelitian ini akan dilakukan di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Laboratorium Rekayasa Perangkat Lunak (Lab RPL) FMIPA, dan Batik Siger Jl.Bayam No. 38 Perumahan Beringin Raya Kecamatan Kemiling Kota Bandar Lampung

3.2 Bahan dan Alat

Bahan dan alat yang digunakan dalam penelitian ini ialah :

3.2.1 Bahan Penelitian

Penelitian ini menggunakan *dataset* yang berisi gambar motif batik lampung. Gambar motif batik lampung yang digunakan dalam penelitian ini adalah 500 gambar yang memiliki jumlah kelas 10 kelas dengan masing-masing gambar pada setiap kelasnya memiliki jumlah 50 gambar. *Dataset* didapatkan dari rumah pembuatan batik lampung atau yang biasa disebut dengan Batik Siger. Kelas pada motif batik lampung yang digunakan yaitu Siger Ratu Agung, Sembagi, Jung Agung, Siger Kembang Cengkikh, Siger Tangkup Betik, Siger Pakjimo, Granitan dan Soga.

3.2.2 Alat Penelitian

Alat yang digunakan pada penelitian antara lain :

3.2.2.1 Perangkat Lunak

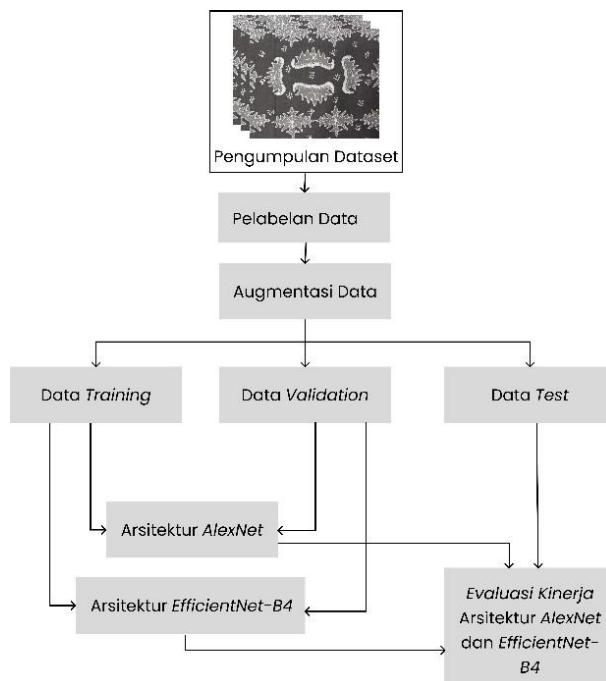
Perangkat lunak yang akan digunakan sebagai pendukung dalam proses identifikasi motif batik lampung adalah sistem operasi *Windows 10 64-bit*, *Google colab*, *Jupyter Notebook*, dan *Google Grive*.

3.2.2.2 Perangkat Keras

Komputer GPU NVIDIA Tesla K20, kamera Canon Eos 250D, Laptop Acer Aspire E5-475G dengan spesifikasi RAM 12 GB, *Harddisk* 1 TB, SSD 256 GB, dan

processor Intel(R) Core(TM) i5-7200U CPU 2.50GHz sebagai alat penelitian untuk proses identifikasi motif batik lampung.

3.3 Metode Penelitian



Gambar 18. Alur Penelitian.

Tahapan yang akan dilalui dalam penelitian ini dapat dilihat pada Gambar 18 dan berikut penjelasannya.

3.3.1 Pengumpulan Dataset

Penelitian dimulai dengan mengumpulkan *dataset* sebagai bahan utama penelitian. *Dataset* yang telah dikumpulkan sebanyak 500 gambar motif batik lampung dengan 10 kelas. Gambar untuk setiap kelasnya dipisahkan dengan menyimpannya kedalam sebuah folder dengan penamaan sesuai dengan tiap-tiap kelasnya. Mesin kemudian akan membaca *dataset* pada awal prosesnya, mesin akan membaca gambar motif batik lampung serta nama kelas yang terdapat pada setiap folder. Penyimpanan gambar melalui *google drive* agar memudahkan saat penggunaan data ke *google colab*. Gambar motif batik juga disimpan kedalam komputer Tesla.

3.3.2 Pelabelan Data

Pelabelan data pada dataset merupakan proses memberikan informasi atau label kepada setiap contoh data dalam dataset. Label ini berfungsi untuk mengidentifikasi atau mengkategorikan data, sehingga model pembelajaran mesin atau deep learning dapat memahami dan memproses informasi dengan lebih baik. Pelabelan data pada dataset dapat mencakup berbagai jenis tugas, tergantung pada tujuan analisis data yang akan dilakukan.

3.3.3 Augmentasi Data

Augmentasi diterapkan untuk membandingkan akurasi antara model sebelum dan setelah augmentasi dilakukan. Ada beberapa jenis Augmentasi data yang tersedia, seperti *flip horizontal* dan *vertical*, *shift*, *rotate*, *brightness*, dan *zoom*. Penelitian ini menggunakan teknik *rotate*, *shift*, dan *zoom*, dengan mengubah ukuran data menjadi 224 x 224 piksel. Penggunaan teknik augmentasi *rotate*, *shift*, dan *zoom* dipilih karena dapat meningkatkan keragaman data dengan menghasilkan versi baru dari dataset yang ada dengan memvariasikan posisi, skala, dan orientasi objek. Augmentasi juga dapat meningkatkan kinerja suatu model, dengan menggunakan data hasil augmentasi model dapat mencapai tingkat akurasi yang lebih tinggi, penelitian CNN pada motif batik menggunakan augmentasi *rotate*, *shift*, dan *zoom* dilakukan oleh syeufin mendapatkan tingkat akurasi sebesar 100%. Augmentasi data dapat mencegah terjadinya *overfitting* dengan menggunakan variasi data dalam proses pelatihan data. Hasil gambar dari augmentasi kemudian digabungkan dengan *dataset* awal, sehingga secara keseluruhan terdapat 1000

3.3.4 Pembagian data

Pembagian data dilakukan dengan membagi data menjadi 3 bagian utama yaitu data *training*, data *validation*, dan data *test*. Data *training* dibutuhkan untuk bahan utama untuk melatih data. Data *training* sendiri memerlukan sekitar 70% dari keseluruhan gambar. Data *validation* menggunakan data sebesar 15% dari keseluruhan gambar. Data *test* digunakan untuk uji performa dan tingkat keberhasilan sebuah model, data yang digunakan pada data *test* menggunakan data sebesar 15% keseluruhan gambar.

Pembagian data antara data *training* sebesar 70%, data *validation* sebesar 15% dan data *test* sebesar 15% bertujuan agar model dapat belajar dengan baik, namun tetap memiliki data yang cukup untuk validasi dan pengujian sehingga dapat mengukur seberapa baik model dapat bekerja pada data baru yang belum pernah dilihat sebelumnya, dengan jumlah data yang cukup untuk pelatihan dapat mencegah terjadinya *overfitting* dimana model belajar terlalu baik pada data yang sudah ada.

3.3.5 Training Arsitektur *AlexNet* dan *EfficientNet-B4*

Tahapan melatih data menggunakan dua model arsitektur yaitu *AlexNet* dan *EfficientNet-B4*. Model ini akan digunakan untuk melakukan perbandingan akurasi diantara keduanya. Pelatihan data menggunakan beberapa *hyperparameter* seperti *epoch*, *batch-size*, *optimizer*, dan *learning-rate* yang digunakan untuk penunjang keberhasilan suatu model dalam melakukan pelatihan dan pengujian data. Kedua model nantinya akan menggunakan *hyperparameter* dengan nilai yang dapat dilihat pada Tabel 3.

Tabel 3. *Hyperparameter* model

<i>Hyperparameter</i>	Jenis/Nilai
<i>Epoch</i>	10
<i>Batch-size</i>	8
<i>Optimizer</i>	Adam
<i>Learning-rate</i>	0.0001

Hyperparameter yang digunakan pada penelitian ini ditentukan dari percobaan dengan menggunakan beberapa *library keras callbacks* diantaranya *ReduceLROnPlateau*, dan *EarlyStopping*. *ReduceLROnPlateau* adalah teknik yang digunakan untuk mengurangi *learning rate* pada saat proses *training* data mengalami perlambatan dalam peningkatan kinerja. *EarlyStopping* adalah teknik yang digunakan untuk menghentikan secara otomatis ketika tidak terjadi peningkatan dalam kinerja sebuah model *deep learning* dalam beberapa *epoch* (iterasi pelatihan). Penentuan *learning rate* dan *epoch* menggunakan teknik

ReduceLROnPlateau dan *EarlyStopping*, sedangkan untuk menentukan jumlah *batch size* dilakukan dengan melakukan beberapa percobaan yang dipilih berdasarkan hasil kinerja model yang paling baik.

3.3.6 Evaluasi Kinerja Arsitektur *AlexNet* dan *EfficientNet-B4*

Evaluasi kinerja dalam penelitian *deep learning* adalah tahap kunci dalam memahami sejauh mana suatu model atau algoritma yang dikembangkan berhasil memenuhi tujuan penelitian. Evaluasi ini melibatkan sejumlah langkah penting, dimana akurasi model perlu diperiksa, agar mengetahui sejauh mana model dapat menghasilkan prediksi yang benar terhadap data uji atau data yang belum pernah dilihat sebelumnya. Aspek seperti *F1-score*, *precision*, *accuracy*, dan *recall* perlu dievaluasi. Pengukuran waktu komputasi dan konsumsi sumber daya adalah aspek yang tidak boleh dilupakan dalam proses evaluasi.

V. KESIMPULAN DAN SARAN

5.1 Simpulan

Simpulan yang didapatkan dari penelitian yang dilakukan adalah sebagai berikut :

1. Identifikasi jenis citra batik lampung menggunakan arsitektur *AlexNet* dan *EfficientNet-B4* berhasil dilakukan dengan penambahan *Augmentasi data rotate, shift, dan zoom*.
2. Arsitektur *EfficientNet-B4* menggunakan *Augmentasi rotate, shift, dan zoom* mencapai tingkat akurasi tertinggi dalam memprediksi kelas batik lampung sebesar 98.00%, sedangkan arsitektur *AlexNet* mendapat tingkat akurasi sebesar 95.33%.
3. Arsitektur *EfficientNet-B4* memiliki jumlah parameter lebih sedikit dibandingkan dengan *AlexNet*, namun arsitektur *EfficientNet-B4* dapat mencapai tingkat akurasi tertinggi dengan menggunakan blok MBConv yang dirancang dengan sangat efisien untuk mengekstrasi fitur dengan lebih sedikit parameter.

5.2 Saran

Saran yang diberikan untuk penelitian selanjutnya adalah sebagai berikut :

1. Memperluas variasi gambar dengan menambahkan lebih banyak kelas batik lampung untuk meningkatkan keberagaman dan keakuratan model.
2. Menggunakan *hyperparameter* yang lebih beragam serta mencoba berbagai arsitektur CNN lainnya, seperti VGG-16, ResNet-50, *Inception*, *YOLOv5*.

DAFTAR PUSTAKA

- Afaq, S., & Rao, S. (2020). Significance Of Epochs On Training A Neural Network. *International Journal of Scientific & Technology Research*, 9(06), 485–488. www.ijstr.org
- 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>
- 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>
- Anggraini, E., Suryanti, C., Nurbella, T., & Sholihin, M. (2022). *Alexnet Arsitektur Untuk Klasifikasi Jenis Batik Lamongan*. 6(02), 54–60.
- Aras, S., Setyanto, A., & Rismayani. (2022). Deep Learning Untuk Klasifikasi Motif Batik Papua Menggunakan EfficientNet dan Trasnfer Learning. *Insect (Informatics and Security): Jurnal Teknik Informatika*, 8(1), 11–20. <https://doi.org/10.33506/insect.v8i1.1865>
- Ashiquuzzaman, 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
- Astawan, N. W. (2021). Siger: Salah Satu Corak Khas Batik Andanan Lampung. *Jurnal Penelitian Humaniora*, 25(2), 67–77. <https://doi.org/10.21831/hum.v25i2.40208>
- Atila, Ü., Uçar, M., Akyol, K., & Uçar, E. (2021). Plant leaf disease classification using EfficientNet deep learning model. *Ecological Informatics*, 61(October 2020), 101182. <https://doi.org/10.1016/j.ecoinf.2020.101182>
- Azahro Choirunisa, N., Karlita, T., & Asmara, R. (2021). Deteksi Ras Kucing Menggunakan Compound Model Scaling Convolutional Neural Network. *Technomedia Journal*, 6(2), 236–251. <https://doi.org/10.33050/tmj.v6i2.1704>
- 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.
- Bodapati, J. D., & Veeranjaneyulu, N. (2019). Feature extraction and classification using Deep convolutional Neural Networks. *Journal of Cyber Security and Mobility*, 8(2), 261–276. <https://doi.org/10.13052/jcsm2245-1439.825>
- Dewanti, A. R. (2021). Inovasi Seni Batik Dalam Media Gutha Tamarin. ... *Seminar Nasional Industri Kerajinan Dan Batik*, 1. <https://117.102.64.59/index.php/SNBK/article/view/109>
- 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.
- Ghawi, R., & Pfeffer, J. (2019). Efficient Hyperparameter Tuning with Grid Search for Text Categorization using kNN Approach with BM25 Similarity. *Open Computer Science*, 9(1), 160–180. <https://doi.org/10.1515/comp-2019-0011>

- Han, X., Zhong, Y., Cao, L., & Zhang, L. (2017). Pre-trained alexnet architecture with pyramid pooling and supervision for high spatial resolution remote sensing image scene classification. *Remote Sensing*, 9(8). <https://doi.org/10.3390/rs9080848>
- Husen, D., Kusrini, K., & Kusnawi, K. (2022). Deteksi Hama Pada Daun Apel Menggunakan Algoritma Convolutional Neural Network. *Jurnal Media Informatika Budidarma*, 6(4), 2103. <https://doi.org/10.30865/mib.v6i4.4667>
- Ibda, H. (2021). Strategi memutus mata rantai pembajakan hak cipta pada seni batik nusantara. *Citra Ilmu*, XVII(33), 65–78.
- Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network. *JUSTINDO (Jurnal Sistem Dan Teknologi Informasi Indonesia)*, 3(2), 49–56.
- 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.poltekegal.ac.id/index.php/informatika/article/view/2802>
- Jalled, F., & Voronkov, I. (2016). *Object Detection using Image Processing*. 1–6.
<http://arxiv.org/abs/1611.07791>
- Kholik, A. (2021). Klasifikasi Menggunakan Convolutional Neural Network (Cnn) Pada Tangkapan Layar Halaman Instagram. *Jdmsi*, 2(2), 10–20.
- Kusnadi, A., & Pratama, J. (2017). Implementasi Algoritma Genetika dan Neural Network Pada Aplikasi Peramalan Produksi Mie. *Jurnal ULTIMATICS*, 9(1), 37–41. <https://doi.org/10.31937/ti.v9i1.562>
- 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>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Lesmana, A. M., Fadhillah, R. P., & Rozikin, C. (2022). Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN). *Jurnal Sains Dan Informatika*, 8(1), 21–30. <https://doi.org/10.34128/jsi.v8i1.377>
- Liu, T., Fang, S., Zhao, Y., Wang, P., & Zhang, J. (2015). *Implementation of Training Convolutional Neural Networks*. <http://arxiv.org/abs/1506.01195>
- Maulana, F. F., & Rochmawati, N. (2020). Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science (JINACS)*, 1(02), 104–108. <https://doi.org/10.26740/jinacs.v1n02.p104-108>
- 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>
- Mukhlash, I., Arham, A. Z., Rozi, F., Kimura, M., & Adzkiya, D. (2018). Opinion mining on book review using convolutional neural network algorithm - Long short term memory. *International Journal of Machine Learning and Computing*, 8(5), 437–441. <https://doi.org/10.18178/ijmlc.2018.8.5.725>
- Pangkasidhi, A. K., Palit, H. N., & Tjondrowiguno, A. N. (2021). Aplikasi Pendukung Diagnosis COVID-19 Yang Menganalisis Hasil X-Ray Paru-Paru Dengan Model EfficientNet. *Jurnal Infra*, 9(2)(031), 1–6.
- Ramadhani, R. A., Wahyu, B., & Purbaningtyas, R. (2021). Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur

- EfficientNet-B3. *JUST IT : Jurnal Sistem Informasi, Teknologi Informasi, Dan Komputer*, 11(3), 55–59.
- 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>
- 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>
- Sentosa, E., Mulyana, D. I., Cahyana, A. F., & Pramuditasari, N. G. (2022). Implementasi Image Classification Pada Batik Motif Bali Dengan Data Augmentation dan Convolutional Neural Network. *Jurnal Pendidikan Tambusai*, 6(1), 1451–1463.
- Setiawan, T., & Avianto, D. (2020). Implementasi Convolutional Neural Network Untuk Pengenalan Warna Kendaraan. *Naskah Publikasi, FTIE*, Universitas Teknologi Yogyakarta.
- Shah, H. A., Saeed, F., Yun, S., Park, J. H., Paul, A., & Kang, J. M. (2022). A Robust Approach for Brain Tumor Detection in Magnetic Resonance Images Using Finetuned EfficientNet. *IEEE Access*, 10, 65426–65438. <https://doi.org/10.1109/ACCESS.2022.3184113>
- 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>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15, 1929–1958.

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/>

Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *36th International Conference on Machine Learning, ICML 2019, 2019-June*, 10691–10700.

Yildirim, M., & Cinar, A. (2020). Classification of Alzheimer's disease MRI images with CNN based hybrid method. *Ingenierie Des Systemes d'Information*, 25(4), 413–418. <https://doi.org/10.18280/isi.250402>