

**EVALUASI KINERJA ARSITEKTUR CONVOLUTIONAL NEURAL
NETWORK (CNN) YOLOv10 UNTUK IDENTIFIKASI
MOTIF BATIK LAMPUNG**

(Skripsi)

Oleh

**ADLI FIQRULLAH
2117051075**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

**EVALUASI KINERJA ARSITEKTUR CONVOLUTIONAL NEURAL
NETWORK (CNN) YOLOv10 UNTUK IDENTIFIKASI
MOTIF BATIK LAMPUNG**

Oleh

ADLI FIQRULLAH

Skripsi

**Sebagai Salah Satu Syarat Untuk Mencapai Gelar
SARJANA ILMU KOMPUTER**

Pada

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



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

EVALUASI KINERJA ARSITEKTUR CONVOLUTIONAL NEURAL NETWORK (CNN) YOLOv10 UNTUK IDENTIFIKASI MOTIF BATIK LAMPUNG

Oleh

ADLI FIQRULLAH

Batik merupakan warisan budaya Indonesia yang memiliki nilai historis, filosofis, dan estetis tinggi. Salah satu batik daerah yang merepresentasikan kekayaan budaya lokal adalah batik Lampung. Motif khas seperti Jung Agung, Siger Kembang Cengkih, dan Sembagi mencerminkan identitas masyarakat Lampung. Upaya pelestarian diperlukan agar warisan ini tetap dikenal lintas generasi. Digitalisasi berbasis kecerdasan buatan memberikan pendekatan baru untuk memperkuat pelestarian budaya melalui pemanfaatan teknologi pengenalan citra. Arsitektur *You Only Look Once* (YOLO) berpotensi digunakan dalam proses deteksi motif batik secara otomatis dan *real-time*. Penelitian ini bertujuan untuk membandingkan performa seluruh varian arsitektur YOLOv10 dalam mengenali motif batik Lampung. *Dataset* terdiri atas 14 kelas dan diperoleh dari 1200 *frame* hasil ekstraksi video yang telah diaugmentasi serta dianotasi secara manual. Jumlah total *bounding box* yang dihasilkan mencapai hingga 4143. Evaluasi performa dilakukan menggunakan metrik *Intersection over Union* (IoU), *precision*, *recall*, *f1-score*, *average precision* (AP), dan *mean Average Precision* (mAP@50). Efisiensi model juga diukur berdasarkan nilai *frame per second* (FPS) dan durasi inferensi. Hasil menunjukkan YOLOv10l mencapai mAP@50 sebesar 92,44% sebagai nilai tertinggi. Varian YOLOv10s mencatat waktu inferensi tercepat yaitu 2,03 menit dan FPS sebesar 88,12. Varian YOLOv10l sesuai diterapkan pada sistem yang membutuhkan akurasi tinggi, sedangkan YOLOv10s lebih tepat untuk sistem *real-time* dengan keterbatasan komputasi.

Kata Kunci: Batik Lampung, Deteksi Objek, YOLOv10.

ABSTRACT

PERFORMANCE EVALUATION OF THE YOLOv10 CONVOLUTIONAL NEURAL NETWORK (CNN) ARCHITECTURE FOR IDENTIFYING LAMPUNG BATIK MOTIFS

By

ADLI FIQRULLAH

Batik is an Indonesian cultural heritage with high historical, philosophical, and aesthetic value. One regional batik that represents local cultural richness is Lampung batik. Distinctive patterns such as Jung Agung, Siger Kembang Cengkih, and Sembagi reflect the identity of the Lampung community. Preservation efforts are essential to ensure this heritage remains recognized across generations. Artificial intelligence-based digitalization offers a new approach to strengthen cultural preservation through image recognition technology. The You Only Look Once (YOLO) architecture has the potential to be utilized for automated and real-time batik motif detection. This study aims to compare the performance of all YOLOv10 architecture variants in recognizing Lampung batik motifs. The dataset consists of 14 classes and was obtained from 1200 frames extracted from video, which were augmented and manually annotated. A total of 4143 bounding boxes were generated. Performance evaluation was conducted using metrics including Intersection over Union (IoU), precision, recall, F1-score, average precision (AP), and mean Average Precision (mAP@50). Model efficiency was measured based on frames per second (FPS) and inference duration. The results show that YOLOv10l achieved the highest mAP@50 score of 92,44%. YOLOv10s recorded the fastest inference time of 2,03 minutes and an FPS of 88,12. YOLOv10l is suitable for systems requiring high accuracy, while YOLOv10s is more appropriate for real-time systems with limited computational resources.

Keywords: Lampung Batik, Object Detection, YOLOv10.

Judul Skripsi

: **EVALUASI KINERJA ARSITEKTUR
CONVOLUTIONAL NEURAL NETWORK
(CNN) YOLOv10 UNTUK IDENTIFIKASI
MOTIF BATIK LAMPUNG**

Nama Mahasiswa

: **Adli Fiqrullah**

Nomor Pokok Mahasiswa

: 2117051075

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


2. Ketua Jurusan Ilmu Komputer

Dwi Sakethi, S.Si., M.Kom.
NIP. 19680611 199802 1 001

MENGESAHKAN


1. Tim Penguji

Ketua : **Rico Andrian, S.Si., M.kom.**




Penguji Pembahas I : **Favorisen R. Lumbanraja, Ph.D**

Penguji Pembahas II : **Rahman Taufik, S.Pd., M. Kom.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi: **20 Juni 2025**

PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Adli Fiqrullah

NPM : 2117051075

Dengan ini menyatakan bahwa skripsi saya yang berjudul **“Evaluasi Kinerja Arsitektur Convolutional Neural Network (CNN) YOLOv10 Untuk Identifikasi Motif Batik Lampung”** merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya tulis ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil jiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 7 Juli 2025

Penulis,



Adli Fiqrullah
NPM. 2117051075

RIWAYAT HIDUP



Lahir di Medan pada tanggal 7 Mei 2003 sebagai anak pertama dari pasangan Bapak Syahrudin dan Ibu Susi Layanti. Pendidikan yang ditempuh penulis diantaranya, menyelesaikan pendidikan dasar di SD Melati Medan pada tahun 2015, pendidikan menengah pertama di SMP Bonapasogit Sejahtera Tobasa pada tahun 2018, dan pendidikan menengah atas di SMA Negeri 2 Plus Sipirok pada tahun 2021. Perjalanan pendidikan penulis dilanjutkan dengan terdaftar sebagai mahasiswa Jurusan Ilmu Komputer di Universitas Lampung melalui jalur SBMPTN pada tahun 2021.

Selama menjadi mahasiswa di Ilmu Komputer, penulis aktif di dalam berbagai kegiatan baik di dalam maupun di luar Universitas Lampung. Kegiatan yang dilakukan adalah sebagai berikut:

1. Menjadi Anggota Bidang Kajian dan Aksi Strategis Badan Eksekutif Mahasiswa Fakultas MIPA pada tahun 2023.
2. Menjadi Anggota Bidang Badan Khusus Himpunan Mahasiswa Jurusan Ilmu Komputer pada tahun 2023.
3. Menjadi Asisten Dosen Jurusan Ilmu Komputer untuk mata kuliah Struktur Data dan Algoritma pada tahun 2023, Pemrograman Berorientasi Objek pada tahun 2023, dan Kecerdasan Buatan pada tahun 2024.
4. Menjadi Koordinator Divisi Olimpiade Ilmu Komputer pada acara MIPA Expo pada tahun 2023.
5. Mengikuti Kuliah Kerja Nyata (KKN) Periode I tahun 2025 di Desa Negeri Pandan, Kecamatan Kalianda, Kabupaten Lampung Selatan.

PERSEMBAHAN

Segala puji dan syukur saya panjatkan ke hadirat Allah Subhanahu wa Ta'ala atas limpahan rahmat dan karunia-Nya. Shalawat serta salam semoga senantiasa tercurah kepada Nabi Muhammad Shallallahu 'Alaihi wa Sallam, berkat petunjuk dan teladan beliau saya dapat menyelesaikan penyusunan skripsi ini.

Skripsi ini saya persembahkan kepada:

kedua orang tua saya serta seluruh rekan yang telah mendampingi dan memberikan dukungan selama proses penyusunan skripsi ini, saya sampaikan rasa terima kasih yang sebesar-besarnya. Ucapan terima kasih juga saya tujukan kepada diri saya sendiri atas keberhasilan menyelesaikan pendidikan di Program Studi S1 Ilmu Komputer, Universitas Lampung.

MOTTO

“I don’t have friends. I got family”

- Dominic Toretto

SANWACANA

Puji syukur kehadiran Allah Subhanahu wa Ta'ala, yang telah memberikan rahmat dan hidayat-Nya kepada penulis, sehingga penulis dapat menyelesaikan skripsi ini tepat waktu. Shalawat serta salam penulis sanjungan kepada Nabi Muhammad Shallallahu 'alaihi wa sallam yang penulis harapkan syafaatnya di hari akhir kelak. Skripsi yang berjudul **“Evaluasi Kinerja Arsitektur Convolutional Neural Network (CNN) YOLOv10 Untuk Identifikasi Motif Batik Lampung”** ini disusun sebagai salah satu syarat untuk memperoleh gelar sarjana pada Program Studi S1 Ilmu Komputer di Universitas Lampung.

Pada kesempatan ini penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan bantuan dan dukungan, baik dalam penyusunan skripsi ini maupun selama perjalanan perkuliahan penulis secara keseluruhan, yaitu:

1. Kepada kedua orang tua tercinta, Ayah dan Umi, serta adik penulis, Hiqmatul Fadillah, atas doa, semangat, dan kepercayaan yang tiada henti dalam mendukung penulis menyelesaikan skripsi ini.
2. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
3. Bapak Dwi Sakethi, S.Si., M.Kom., selaku Ketua Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
4. Ibu Yunda Heningtyas, M.Kom., selaku Sekretaris Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Ibu Ossy Dwiendah Wulansari, S.Si., M.T., selaku Dosen Pembimbing Akademik yang telah memberikan bimbingan selama masa studi.
6. Bapak Tristiyanto, S.Kom., M.I.S., Ph, selaku Ketua Program Studi S1 Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

7. Bapak Rico Andrian, S.Si., M.Kom., selaku dosen Pembimbing Utama yang telah membimbing dan memberikan banyak arahan kepada penulis sehingga penelitian yang penulis lakukan dapat menjadi lebih baik.
8. Bapak Favorisen R. Lumbanraja, Ph.D, selaku dosen Pembahas Pertama yang telah memberikan kritik dan saran yang membangun serta kontribusinya dalam penyempurnaan penulisan skripsi ini.
9. Bapak Rahman Taufik, S.Pd., M.Kom., selaku dosen Pembahas Kedua yang telah memberikan masukan dan saran yang membangun serta kontribusinya dalam penyempurnaan penulisan skripsi ini.
10. Bapak dan Ibu Dosen Jurusan Ilmu Komputer Universitas Lampung yang telah memberikan ilmu, pengetahuan, serta pengalaman terbaik selama penulis menjadi mahasiswa.
11. Seluruh Staf Jurusan Ilmu Komputer, termasuk Ibu Ade Nora Maela, yang senantiasa membantu dan memberikan pelayanan terbaik dari awal hingga akhir masa perkuliahan.
12. Auvar Mahsa Fahlevi, selaku rekan skripsi yang saling bantu-membantu dalam proses pengerjaan skripsi.
13. Seluruh teman-teman seperjuangan, khususnya Ucup Family dan Atsalsuki 84 yang telah menemani penulis dengan dukungan, motivasi, dan kebersamaan yang sangat berharga.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna, oleh karena itu kritik dan saran yang membangun sangat penulis harapkan demi perbaikan di masa mendatang. Semoga skripsi ini dapat memberikan manfaat bagi semua pihak.

Bandar Lampung, 7 Juli 2025

Adli Fiqrullah
NPM. 2117051075

DAFTAR ISI

	Halaman
DAFTAR TABEL	iii
DAFTAR GAMBAR.....	iv
I. PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
II. TINJAUAN PUSTAKA.....	5
2.1 Penelitian Terdahulu.....	5
2.2 Batik	8
2.3 Batik Lampung	8
2.4 Citra Digital	16
2.5 <i>Deep Learning</i>	16
2.6 <i>Convolutional Neural Network (CNN)</i>	17
2.7 <i>You Only Look Once v10 (YOLOv10)</i>	20
2.8 <i>Hyperparameter</i>	22
2.9 Anotasi.....	23
2.10 <i>Computer Vision Annotation Tool (CVAT)</i>	24
2.11 <i>Intersection over Union (IoU)</i>	25
2.12 <i>Confusion Matrix</i>	26
2.13 <i>mean Average Precision (mAP)</i>	28
2.14 <i>Overfitting</i>	28
2.15 <i>Underfitting</i>	29

III. METODOLOGI PENELITIAN	30
3.1 Waktu dan Tempat	30
3.2 Alat dan Bahan	31
3.3 Alur Penelitian.....	32
IV. HASIL DAN PEMBAHASAN	35
4.1 Pengumpulan <i>Dataset</i>	35
4.2 <i>Preprocessing</i>	36
4.3 Anotasi Data	38
4.4 <i>Splitting</i> Data	40
4.5 <i>Training</i> Arsitektur.....	41
4.6 Evaluasi Arsitektur	51
V. SIMPULAN DAN SARAN	63
5.1 Simpulan.....	63
5.2 Saran	63
DAFTAR PUSTAKA	64
LAMPIRAN.....	68

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu Terkait dengan Penelitian Arsitektur YOLO dan Objek Motif Batik Lampung.....	5
2. <i>Confusion Matrix</i>	26
3. Rencana Penelitian	30
4. Konfigurasi <i>Hyperparameter</i>	34
5. Video Rekaman <i>Dataset</i>	35
6. Hasil Anotasi Perkelas	39
7. Skenario Pembagian Data	40
8. Model <i>Summary Backbone</i> YOLOv10	43
9. Model <i>Summary Neck</i> YOLOv10	45
10. Model <i>Summary Head</i> YOLOv10	46
11. Ringkasan Model <i>Summary</i> YOLOv10	46
12. Rata-rata IoU Setiap Varian	54
13. Nilai AP Setiap Varian.....	58

DAFTAR GAMBAR

Gambar	Halaman
1. Batik Sembagi	9
2. Batik Granitan	9
3. Batik Jung Agung.....	10
4. Batik Kembang Cengkih.....	10
5. Batik Kambil Sicukil.....	11
6. Batik Siger Ratu Agung	11
7. Batik Abstrak	12
8. Batik Sekar Jagat.....	12
9. Batik Sinaran.....	13
10. Batik Tambal.....	13
11. Batik Adiwarna	14
12. Batik Liman.....	14
13. Batik Menara Siger	15
14. Batik Kupi	15
15. CNN <i>Architecture</i>	18
16. Ilustrasi <i>Convolutional Layer</i>	19
17. Ilustrasi <i>Pooling Layer</i>	20
18. YOLOv10 <i>Architecture</i>	21
19. Ilustrasi Deteksi IoU	25
20. Alur Penelitian	32
21. Proses Pengumpulan <i>Dataset</i>	36
22. Proses <i>Preprocessing</i>	37
23. Proses Anotasi Data Pada <i>Platform CVAT</i>	38
24. Tampilan File Hasil Anotasi <i>Frame_001160</i>	39
25. Situs <i>Website</i> Ultralytics	42
26. Visualisasi Arsitektur YOLOv10.....	43

27. <i>Epoch</i> dan Durasi Pelatihan Model YOLOv10.....	48
28. Performa Model Pada Data <i>Validation</i>	49
29. Area <i>Ground Truth</i> dan Prediksi <i>Bounding Box</i>	51
30. <i>Intersection Bounding Box</i>	52
31. <i>Confusion Matrix</i> Setiap Varian.....	57
32. Grafik AP Setiap Varian	59
33. Performa Model Pada Data <i>Testing</i>	60
34. Efisiensi Model Setiap Varian	61

I. PENDAHULUAN

1.1 Latar Belakang

Batik sebagai salah satu warisan budaya yang telah diakui oleh *United Nations Educational, Scientific, and Cultural Organization* (UNESCO) memiliki berbagai motif yang mencerminkan kekayaan budaya Indonesia. Setiap daerah di Nusantara, termasuk Lampung, memiliki motif batik khas seperti Jung Agung, Siger Kembang Cengkih, dan Sembagi. Perkembangan globalisasi meningkatkan pentingnya pelestarian budaya melalui media digital untuk mempertahankan dan memperkenalkan kekayaan ini kepada dunia. Upaya yang dapat dilakukan adalah identifikasi motif batik Lampung agar masyarakat awam dapat dengan mudah mengenali jenis batik tersebut. Teknologi pengenalan citra berdasarkan ciri dan pola khas menjadi kebutuhan penting dalam mendukung penelitian di bidang ini. Aplikasi seperti *iWareBatik* telah menyediakan fitur pengenalan motif batik dari gambar statis, namun memiliki keterbatasan dalam mendeteksi secara *real-time*. Perkembangan teknologi saat ini semakin pesat, khususnya dalam pengenalan objek. Teknologi *computer vision* berbasis *deep learning*, seperti *Convolutional Neural Network* (CNN) memungkinkan untuk mendeteksi secara *real-time* yang sebelumnya sulit dicapai oleh teknologi konvensional.

Convolutional Neural Network (CNN) adalah metode *deep learning* yang dirancang untuk menganalisis dan mengenali pola dalam gambar. CNN bekerja dengan memanfaatkan lapisan konvolusi untuk mengambil fitur penting dari data gambar. CNN pertama kali diterapkan pada pengenalan angka tulisan tangan dan menghasilkan tingkat kesalahan rendah melalui penggunaan koneksi lokal dan *subsampling* (Le Cun *et al.*, 1989). CNN memiliki kemampuan belajar langsung dari data tanpa memerlukan ekstraksi fitur manual, sehingga lebih unggul dalam

tugas seperti identifikasi objek dan deteksi pola. CNN juga berhasil digunakan dalam identifikasi motif batik dengan akurasi tinggi, bahkan pada *dataset* yang memiliki variasi gambar seperti kecerahan tidak merata atau adanya objek tambahan dalam gambar (Uswatun Khasanah *et al.*, 2020).

You Only Look Once (YOLO) adalah salah satu arsitektur CNN yang memperkenalkan pendekatan baru dalam identifikasi objek. Metode ini dikembangkan oleh Joseph Redmon, Santosh Divvala, Ross Girshick, dan Ali Farhadi pada tahun 2016. Pendekatan ini berbeda dari metode sebelumnya yang memanfaatkan *classifier* untuk identifikasi objek. YOLO mengubah masalah identifikasi objek menjadi masalah *regresi*, di mana seluruh gambar diproses oleh satu jaringan saraf untuk langsung memprediksi *bounding box* dan probabilitas kelas objek. YOLO menggunakan arsitektur CNN yang memungkinkan sistem untuk melihat seluruh gambar sekaligus, baik pada saat pelatihan maupun pengujian, sehingga mampu memahami konteks dan memprediksi objek secara lebih efisien dan cepat. YOLO mampu memproses hingga 45 *frame* per detik pada gambar penuh, menjadikannya sangat cepat dibandingkan metode lainnya. YOLO menggunakan CNN sebagai dasar untuk ekstraksi fitur dan prediksi *bounding box* pada gambar, sehingga memungkinkan identifikasi objek secara *real-time* dengan akurasi yang tinggi (Redmon *et al.*, 2016).

Penelitian yang menerapkan arsitektur YOLO berkaitan dengan deteksi kebakaran di lingkungan bangunan dan pabrik menggunakan YOLOv10 yang telah *difine-tuning* untuk meningkatkan akurasi dalam aplikasi *real-time*. Model ini menggunakan teknik pembekuan lapisan awal, mekanisme atensi *Squeeze and Excitation* (SE), serta optimisasi dengan *Stochastic Gradient Descent* (SGD) dengan momentum. *Dataset* khusus kebakaran dalam ruangan dikembangkan melalui teknik augmentasi data guna meningkatkan generalisasi model. Hasil eksperimen menunjukkan model YOLOv10s memberikan keseimbangan terbaik antara akurasi dan waktu prediksi. mAP@50 yang diperoleh sebesar 91,3% dengan waktu inferensi 10,7 ms, lebih baik dibandingkan dengan Faster R-CNN dan *baseline* YOLOv10 (Huynh *et al.*, 2024).

Penelitian lainnya yang menerapkan arsitektur YOLO berkaitan dengan deteksi telur parasit pada citra mikroskopis tinja menggunakan beberapa varian YOLO yang telah dioptimalkan untuk meningkatkan akurasi deteksi dalam pengujian *real-time*. Model ini menggunakan teknik *Grad-CAM* untuk memvisualisasikan kinerja deteksi serta diuji pada *platform embedded* seperti *Raspberry Pi 4*, *Intel upSquared Board*, dan *Jetson Nano*. *Dataset* Chula-ParasiteEgg-11 digunakan dengan teknik augmentasi data untuk meningkatkan generalisasi model. Hasil eksperimen menunjukkan bahwa model YOLOv7-*tiny* memberikan keseimbangan terbaik antara akurasi dan kecepatan prediksi dengan mAP@50 sebesar 98,7% dan waktu inferensi 73 ms, lebih baik dibandingkan dengan varian YOLO lainnya (Venkatesan *et al.*, 2025).

Penelitian yang berkaitan dengan pengenalan motif batik Lampung yaitu menggunakan algoritma *k-Nearest Neighbor* (k-NN). Gambar batik diproses dengan mengubah ukuran menjadi 50x50 piksel dan diubah menjadi *gray scale*, kemudian fitur tekstur diekstraksi menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM). Penelitian dilakukan menggunakan k-NN pada beberapa nilai k dan sudut orientasi berbeda. Hasil terbaik dari penelitian ini adalah akurasi sebesar 97,96% pada nilai k = 7 dan sudut orientasi 135° (Andrian *et al.*, 2019). Studi ini menunjukkan bahwa meskipun metode berbasis k-NN memiliki tingkat akurasi yang cukup tinggi, ada potensi peningkatan performa jika menggunakan pendekatan berbasis *deep learning* seperti CNN.

Penelitian lainnya yang berkaitan dengan pengenalan motif batik Lampung yaitu membandingkan dua arsitektur CNN, LeNet-5 dan MobileNet. Sebanyak 1000 citra batik Lampung dikumpulkan dan dibagi ke dalam 10 kelas berbeda. Teknik augmentasi data, seperti *rotation*, *brightness*, dan *zoom*, digunakan untuk memperluas *dataset* dan meningkatkan kinerja model. LeNet-5 mencapai akurasi 99,33%, sedangkan MobileNet memperoleh akurasi 98,00%. Hasil ini menegaskan bahwa augmentasi data memberikan kontribusi signifikan dalam meningkatkan akurasi model, dengan LeNet-5 unggul dalam hal *presisi* dan *recall* dibandingkan MobileNet (Andrian *et al.*, 2024).

Penelitian ini berfokus pada perbandingan kinerja model dalam mengenali dan mengidentifikasi motif batik Lampung menggunakan seluruh varian arsitektur YOLOv10. Penelitian ini membuka peluang lebih luas untuk penerapan teknologi *deep learning* di berbagai sektor, seperti pelestarian budaya.

1.2 Rumusan Masalah

Rumusan masalah penelitian ini adalah mengevaluasi kinerja arsitektur YOLOv10 dalam mengidentifikasi motif batik Lampung berdasarkan metrik mAP, *precision*, *recall*, dan *F1-score* untuk menentukan model yang paling optimal.

1.3 Batasan Masalah

Batasan masalah penelitian ini terletak pada penggunaan *dataset* yang terdiri dari 14 kelas motif, yaitu abstrak, adiwarna, granitan, jung agung, kambil sicukil, kembang cengkih, kupi, liman, menara siger, sekar jagat, sembagi, siger ratu agung, sinaran, dan tambal. Penelitian ini menggunakan format citra JPG beresolusi 640x640 piksel yang diperoleh dari hasil ekstraksi video berdurasi 40 detik dan menggunakan seluruh varian arsitektur YOLOv10 pada tugas identifikasi.

1.4 Tujuan Penelitian

Tujuan penelitian ini untuk membandingkan kinerja arsitektur YOLOv10 dalam pengenalan dan identifikasi motif batik Lampung.

1.5 Manfaat Penelitian

Penelitian ini dapat memberikan manfaat sebagai acuan bagi penelitian selanjutnya terkait pengenalan motif batik Lampung dengan pendekatan arsitektur YOLOv10.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian ini memiliki keterkaitan dengan penelitian sebelumnya, sehingga terdapat hubungan antara persamaan dan perbedaan pada objek yang diteliti. Rangkuman dari penelitian terdahulu dapat dilihat pada Tabel 1.

Tabel 1. Penelitian Terdahulu Terkait dengan Penelitian Arsitektur YOLO dan Objek Motif Batik Lampung

No	Judul	Data	Kesimpulan
1	<i>Enhancing Fire Detection Performance Based on Fine-Tuned YOLOv10</i>	Dataset terdiri dari 6000 citra (5075 citra <i>indoor</i> dan 925 citra <i>outdoor</i>)	Model YOLOv10s memiliki keseimbangan terbaik antara akurasi dan efisiensi komputasi, dengan mAP@50 sebesar 91,3% dan waktu inferensi 10,7 ms
2	<i>Comparative Analysis of Resource-Efficient YOLO Models for Rapid and Accurate Recognition of Intestinal Parasitic Eggs in Stool Microscopy</i>	Dataset terdiri atas 11 kelas, dengan masing-masing kelas terdapat 1000 citra	Model YOLOv7-tiny memberikan hasil terbaik dengan mAP@50 sebesar 98,7%
3	<i>k-Nearest Neighbor (k-NN) Classification for Recognition of the Batik Lampung Motifs</i>	Dataset terdiri dari 4 motif Lampung dan 2 motif Jawa, dengan masing-masing motif terdapat 25 gambar	Akurasi terbaik diperoleh pada k=7 dengan sudut orientasi 135°, yaitu sebesar 97,96%
4	<i>Performance Comparison Between LeNet and MobileNet in Convolutional Neural Network for Lampung Batik Image Identification</i>	Dataset terdiri dari 10 kelas, dengan masing-masing kelas terdapat 100 citra	LeNet-5 unggul dengan akurasi 99,33%, sementara MobileNet mencapai akurasi 98,00%

Penelitian pertama yang dilakukan oleh Huynh *et al.* (2024) berfokus pada peningkatan kinerja deteksi kebakaran menggunakan arsitektur YOLOv10 yang telah *define-tuning* untuk aplikasi *real-time* di lingkungan bangunan dan pabrik. Penelitian ini bertujuan meningkatkan akurasi deteksi kebakaran melalui pembekuan lapisan awal model, penerapan mekanisme atensi *Squeeze and Excitation* (SE), serta optimisasi menggunakan *Stochastic Gradient Descent* (SGD) dengan momentum. *Dataset* yang digunakan terdiri lebih dari 6000 citra kebakaran dalam ruangan yang diperkaya dengan teknik augmentasi untuk meningkatkan generalisasi model terhadap berbagai kondisi pencahayaan dan lingkungan. Evaluasi model dilakukan berdasarkan metrik mAP@50, serta waktu inferensi untuk mengukur efisiensi dan akurasi sistem. Hasil penelitian menunjukkan bahwa model YOLOv10s memiliki keseimbangan terbaik antara akurasi dan efisiensi komputasi, dengan mAP@50 sebesar 91,3% dan waktu inferensi 10,7 ms, melampaui model *baseline* YOLOv10 serta Faster R-CNN. Tantangan utama dalam penelitian ini meliputi pemeliharaan keseimbangan antara akurasi deteksi yang tinggi dan kecepatan prediksi yang diperlukan dalam sistem peringatan kebakaran secara *real-time*. Optimalisasi model dan augmentasi data menjadi faktor utama dalam meningkatkan performa deteksi kebakaran di berbagai kondisi lingkungan.

Penelitian kedua yang dilakukan oleh Venkatesan *et al.* (2025) berfokus pada evaluasi delapan varian model YOLO, yaitu YOLOv5n, YOLOv5s, YOLOv7, YOLOv7-Tiny, YOLOv8n, YOLOv8s, YOLOv10n, dan YOLOv10s, dalam mendeteksi telur parasit usus pada citra mikroskopis tinja. *Dataset* yang digunakan terdiri dari 11 kelas telur parasit yang dikumpulkan melalui berbagai peralatan mikroskop. Model YOLO dilatih dengan parameter yang sama untuk memastikan perbandingan yang adil. Hasil penelitian menunjukkan bahwa model YOLOv7-tiny memberikan hasil terbaik dengan mAP@50 sebesar 98,7%. Model YOLOv10s, YOLOv8n, YOLOv7, YOLOv8s, YOLOv5s, YOLOv10n, dan YOLOv5n masing-masing mencatatkan mAP@50 sebesar 98,38%, 98,33%, 98,1%, 98,03%, 97,9%, 97,84%, dan 97,7%. YOLOv10s mencatatkan *recall* tertinggi dengan nilai 100%, sementara YOLOv8n memberikan kecepatan inferensi tertinggi dengan 55 *frame* per detik pada pengujian menggunakan *Jetson Nano*. Tantangan utama dalam penelitian ini adalah mencapai keseimbangan antara akurasi dan efisiensi

komputasi, terutama saat diterapkan pada *platform* tertanam seperti *Raspberry Pi 4*, *Intel upSquared Board*, dan *Jetson Nano*. Penelitian ini menunjukkan bahwa model YOLOv7-Tiny sangat cocok untuk deteksi cepat dan akurat dalam pengenalan telur parasit di lingkungan sumber daya terbatas.

Penelitian ketiga yang dilakukan oleh Andrian *et al.* (2019) berfokus pada klasifikasi motif batik Lampung menggunakan metode *k-Nearest Neighbor* (k-NN). Batik Lampung dipilih karena memiliki motif yang unik, seperti Jung Agung, Siger Kembang Cengkih, Sembagi, dan Siger Ratu Agung. Data gambar batik yang digunakan diambil dengan kamera SLR, kemudian diubah menjadi citra *grayscale* dan diperkecil ukurannya menjadi 50x50 piksel. *Dataset* yang digunakan dalam penelitian ini terdiri dari 100 gambar batik Lampung dan 50 gambar batik Jawa, dengan masing-masing motif memiliki 25 gambar. Fitur gambar diekstraksi menggunakan *Gray Level Co-Occurrence Matrix* (GLCM). Algoritma k-NN digunakan untuk mengklasifikasikan motif, dengan berbagai nilai k (3, 5, 7, 9, 11) dan sudut orientasi (0°, 45°, 90°, 135°). Hasil menunjukkan bahwa akurasi terbaik diperoleh pada k=7 dengan sudut orientasi 135°, yaitu sebesar 97,96%. Tantangan utama dalam penelitian ini yaitu menangani variasi pola motif batik Lampung yang rumit dan jumlah *dataset* yang terbatas, sehingga pemilihan parameter k dan sudut orientasi menjadi sangat krusial untuk mendapatkan hasil yang optimal. Penelitian ini menyoroti efisiensi metode k-NN dalam mengenali motif batik Lampung, menunjukkan bahwa kombinasi fitur GLCM dan k-NN mampu menghasilkan kinerja yang optimal.

Penelitian keempat yang dilakukan oleh Andrian *et al.* (2024) berfokus pada perbandingan dua arsitektur *Convolutional Neural Network* (CNN), yaitu LeNet-5 dan MobileNet, dalam mengklasifikasikan motif Batik Lampung. *Dataset* yang digunakan terdiri dari 1000 citra batik Lampung yang terbagi ke dalam 10 kelas, yang telah ditingkatkan dengan teknik augmentasi data seperti *rotation*, *brightness*, dan *zoom* untuk memperbanyak variasi data. Model LeNet-5 dan MobileNet dilatih menggunakan parameter yang sama untuk memastikan evaluasi yang adil. Hasil penelitian menunjukkan bahwa LeNet-5 unggul dengan akurasi 99,33%, sementara MobileNet mencapai akurasi 98,00%. LeNet-5 juga menunjukkan performa yang lebih baik dalam hal *presisi* dan *recall*, terutama dengan penerapan augmentasi

data. Tantangan terbesar dari penelitian ini adalah mengatasi perbedaan performa kedua arsitektur dalam mengenali motif batik Lampung yang rumit, di mana LeNet-5 cenderung lebih baik dalam mengklasifikasikan detail motif, sedangkan MobileNet memberikan kecepatan yang lebih tinggi dengan sedikit penurunan akurasi. Penelitian ini menunjukkan bahwa LeNet-5 lebih cocok untuk tugas pengenalan motif batik Lampung dibandingkan MobileNet, meskipun keduanya memiliki tingkat akurasi yang sangat tinggi.

2.2 Batik

Batik merupakan salah satu warisan budaya asli Indonesia yang memiliki nilai seni tinggi. Sejarah batik menunjukkan perkembangannya dari waktu ke waktu, dengan akulturasi seni yang tercermin melalui corak, ragam hias, dan warna yang melambangkan kehidupan serta kondisi alam. Seni batik pada mulanya berfungsi bukan hanya sebagai keterampilan melukis, tetapi juga bagian dari pendidikan etika dan estetika bagi masyarakat, khususnya wanita zaman dulu. Hingga saat ini, batik masih memegang peran penting dalam kehidupan masyarakat Indonesia dan merupakan simbol warisan budaya yang dijaga dan dilestarikan di berbagai daerah (Hendrawati *et al.*, 2021).

2.3 Batik Lampung

Batik Lampung memiliki kekhasan tersendiri dengan motif yang berasal dari tekstil tradisional Lampung, seperti sembagi dan siger. Lampung pada awalnya tidak memiliki tradisi batik, namun motif-motif ini kemudian berkembang dan mulai dikenal secara luas pada tahun 1970-an. Batik khas Lampung sering digunakan dalam acara-acara penting dan telah mengalami perkembangan yang signifikan dari waktu ke waktu. Beberapa motif batik Lampung terlihat mirip dengan motif dari daerah lain, tetapi mereka tetap memiliki keunikan tersendiri yang membedakannya (Armelia *et al.*, 2024).

2.3.1 Batik Sembagi



Gambar 1. Batik Sembagi.

Batik sembagi memiliki motif mayoritas kembang sembagi. Motif ini memiliki bentuk dan pola yang unik, serta sering digunakan sebagai simbol keindahan dan keanggunan. Motif batik sembagi dapat dilihat pada Gambar 1.

2.3.2 Batik Granitan



Gambar 2. Batik Granitan.

Batik granitan tidak memiliki motif khusus, namun 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. Motif batik granitan dapat dilihat pada Gambar 2.

2.3.3 Batik Jung Agung



Gambar 3. Batik Jung Agung.

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. Motif batik jung agung dapat dilihat pada Gambar 3.

2.3.4 Batik Kembang Cengkih



Gambar 4. Batik Kembang Cengkih.

Batik kembang cengkih memiliki ciri khas dengan corak kembang cengkih yang terkesan natural dan segar. Motif kembang cengkih 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. Motif batik kembang cengkih dapat dilihat pada Gambar 4.

2.3.5 Batik Kambil Sicukil



Gambar 5. Batik Kambil Sicukil.

Batik kambil sicukil memiliki motif ikon di dalam bentuk segitiga. Motif batik kambil sicukil dapat dilihat pada Gambar 5.

2.3.6 Batik Siger Ratu Agung



Gambar 6. Batik Siger Ratu Agung.

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. Motif batik siger ratu agung dapat dilihat pada Gambar 6.

2.3.7 Batik Abstrak



Gambar 7. Batik Abstrak.

Batik abstrak memiliki ciri khas berbagai macam motif ditambahkan ke dalam satu batik, contohnya motif daun, motif garis, warna polos dan lainnya. Motif batik abstrak dapat dilihat pada Gambar 7.

2.3.8 Batik Sekar Jagat



Gambar 8. Batik Sekar Jagat.

Batik sekar jagat memiliki ciri khas motif yang mirip dengan batik kambil sicukil, yaitu identik dengan motif ikon di dalam suatu bentuk sembarang. Motif batik sekar jagat dapat dilihat pada Gambar 8.

2.3.9 Batik Sinaran



Gambar 9. Batik Sinaran.

Batik ini dinamai “sinaran” dikarenakan memiliki ciri khas motif garis membentuk kerucut seperti sinar. Motif batik sinaran dapat dilihat pada Gambar 9.

2.3.10 Batik Tambal



Gambar 10. Batik Tambal.

Batik tambal memiliki ciri khas motif ikon di dalam bentuk persegi seperti beberapa potong kain yang ditambal menjadi satu. Motif batik tambal dapat dilihat pada Gambar 10.

2.3.11 Batik Adiwarna



Gambar 11. Batik Adiwarna.

Motif batik adiwarna menampilkan perpaduan warna-warna mencolok yang menyatukan semua ikon khas Lampung dalam satu kain. Motif batik adiwarna dapat dilihat pada Gambar 11.

2.3.12 Batik Liman



Gambar 12. Batik Liman.

Batik ini dinamai "Liman" karena motifnya menggambarkan sosok gajah, hewan khas Lampung yang melambangkan kekuatan dan kesabaran. Motif batik liman dapat dilihat pada Gambar 12.

2.3.13 Batik Menara Siger



Gambar 13. Batik Menara Siger.

Batik menara siger atau disebut batik menagha siger dalam bahasa Lampung, menampilkan motif menara siger yang menjadi ikon unik khas daerah Lampung. Motif batik menara siger dapat dilihat pada Gambar 13.

2.3.14 Batik Kupi



Gambar 14. Batik Kupi.

Motif batik kupi terinspirasi oleh kopi yang merupakan komoditas utama provinsi Lampung dan mencerminkan peran Lampung sebagai salah satu produsen kopi terbesar di Indonesia. Motif batik kupi dapat dilihat pada Gambar 14.

2.4 Citra Digital

Citra digital merupakan representasi dua dimensi dari bentuk fisik nyata tiga dimensi. Representasi ini dinyatakan dalam bentuk numerik dengan nilai-nilai diskrit untuk memungkinkan pengolahan menggunakan komputer. Proses ini mengubah fungsi kontinu intensitas cahaya pada bidang dua dimensi menjadi matriks yang terdiri atas elemen-elemen terkecil, yaitu piksel. Elemen-elemen ini membentuk gambar secara keseluruhan dan memungkinkan penerapan dalam berbagai bidang seperti analisis data visual dan pengolahan informasi (Putri, 2016).

Citra digital direpresentasikan secara matematis sebagai fungsi $f(x, y)$, di mana x dan y adalah koordinat spasial, sedangkan *amplitude* f menunjukkan intensitas atau tingkat keabuan pada titik tersebut. Fungsi ini memungkinkan citra digital diolah menggunakan teknik seperti segmentasi dan peningkatan kualitas gambar. Salah satu metode penting adalah normalisasi RGB, yang menghitung persentase warna merah, hijau, dan biru dalam setiap piksel untuk mendeteksi objek berdasarkan warna tertentu. Teknik ini efektif meskipun terdapat perubahan intensitas cahaya, tetapi memiliki kelemahan dalam membedakan warna hitam dan putih karena nilai $f(x, y)$ untuk kedua warna tersebut memiliki proporsi RGB yang sama (Kusumanto & Tompunu, 2011). Matematis citra digital dapat dilihat pada Persamaan (1).

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \cdots & f(0, M - 1) \\ f(1, 0) & f(1, 1) & \cdots & f(1, M - 1) \\ \vdots & \vdots & & \vdots \\ f(N - 1, 0) & f(N - 1, 1) & f(N - 1, M - 1) \end{bmatrix} \dots\dots\dots (1)$$

2.5 Deep Learning

Deep learning merupakan subbidang dari *machine learning* yang menggunakan jaringan saraf tiruan berlapis (*deep neural networks*) untuk mengenali pola dalam data berukuran besar. Konsep ini berkembang dari penelitian awal mengenai jaringan saraf tiruan yang diperkenalkan melalui model perceptron oleh Rosenblatt pada tahun 1958. Model ini meniru cara kerja otak dalam menyimpan informasi


dan mengenali pola melalui koneksi antar-neuron buatan yang dapat diperkuat atau dilemahkan berdasarkan pengalaman. Perceptron memiliki keterbatasan dalam menangani masalah non-linear seperti fungsi XOR. Keterbatasan ini mendorong pengembangan arsitektur jaringan yang lebih kompleks agar meningkatkan kemampuan *machine learning* (Rosenblatt, 1958).

Perkembangan signifikan dalam *deep learning* terjadi pada tahun 2006. Hinton dan rekan-rekannya memperkenalkan *deep belief networks* (DBN) sebagai metode baru untuk melatih jaringan saraf yang lebih dalam. Model ini menggunakan pembelajaran tanpa pengawasan agar membangun representasi fitur dari data sebelum melalui tahap *fine-tuning* menggunakan *supervised learning*. Pendekatan ini mengatasi masalah eksplosinya *gradien* dalam *multilayered neural network*. *Deep network* mampu menyerap pola yang lebih kompleks dari data berjumlah besar. Model ini menunjukkan keunggulan dalam tugas klasifikasi serta generasi data, contohnya mencakup pengenalan tulisan tangan dan pemrosesan gambar (Hinton *et al.*, 2006).

2.6 Convolutional Neural Network (CNN)

Convolutional Neural Networks (CNN) adalah salah satu arsitektur *deep learning* yang dirancang untuk tugas pengenalan pola, khususnya dalam pemrosesan citra. CNN bekerja dengan menerapkan beberapa lapisan *convolution* yang berfungsi untuk mengekstraksi fitur-fitur penting dari gambar *input*. CNN telah banyak digunakan dalam klasifikasi citra dan deteksi objek, memberikan hasil yang akurat pada berbagai tugas *computer vision*. Konteks klasifikasi pada CNN melibatkan beberapa komponen utama, seperti lapisan *convolution* dan *pooling* yang berfungsi mengurangi kompleksitas data sambil mempertahankan informasi penting. *Fully connected layer* dan lapisan *softmax* menghasilkan klasifikasi di akhir proses (Ahad *et al.*, 2023). Kesuksesan CNN dalam menyelesaikan berbagai tugas pengenalan dan klasifikasi citra tidak terlepas dari kontribusi awal penelitian yang dilakukan oleh Yann Le Cun dan timnya.

Sejak pertama kali diperkenalkan oleh Yann Le Cun dan timnya dalam studi pengenalan digit tulisan tangan pada tahun 1989, CNN telah menunjukkan kemampuan luar biasa dalam menyelesaikan tugas-tugas pengenalan gambar. Penelitian mereka di *AT&T Bell Laboratories* membuktikan bahwa jaringan *back-propagation* yang besar mampu mengidentifikasi pola pada gambar digit tanpa memerlukan pra-pemrosesan yang kompleks. Hal ini menjadi fondasi bagi kemajuan signifikan di bidang *computer vision*. CNN terus berkembang dan diadaptasi untuk berbagai aplikasi modern seperti pengenalan wajah, kendaraan otonom, serta diagnosis medis berbasis gambar (Le Cun *et al.*, 1989). Arsitektur CNN dapat dilihat pada Gambar 15.



Gambar 15. CNN Architecture (Awaluddin *et al.*, 2023).


CNN terdiri atas beberapa komponen utama yang bekerja secara berurutan untuk melakukan ekstraksi dan klasifikasi fitur pada data gambar. Lapisan pertama yaitu lapisan *convolution* berfungsi menerapkan sejumlah filter terhadap data masukan guna menghasilkan *feature map* yang menyoroti pola-pola visual penting seperti tepi dan tekstur. Lapisan ini diikuti oleh lapisan *pooling* yang berperan dalam mengurangi dimensi *spasial* dari *feature map* dengan tetap mempertahankan informasi penting, serta mengurangi kompleksitas komputasi. Kombinasi dari lapisan *convolution* dan *pooling* menghasilkan representasi fitur yang kemudian diproses oleh lapisan *fully connected*. Lapisan *fully connected* menghubungkan seluruh fitur yang telah diekstraksi untuk menentukan kelas *output* yang paling sesuai dengan menggunakan fungsi *softmax* (Almryad & Kutucu, 2020).

2.6.1 Feature Extraction

Arsitektur CNN menjalankan *feature extraction* melalui lapisan *convolution* yang menerapkan filter untuk menghasilkan *feature map* dari data *input*. Proses ini memungkinkan CNN untuk menangkap pola penting, seperti tekstur dan bentuk dari gambar, yang kemudian digunakan untuk klasifikasi. Arsitektur CNN menempatkan proses ekstraksi fitur di lapisan *convolution* dan *pooling* sebelum akhirnya diproses lebih lanjut di lapisan *fully connected* untuk menghasilkan klasifikasi akhir (Mesárošová *et al.*, 2024).

2.6.1.1 Convolutional Layer


Convolutional layer dalam arsitektur CNN bertanggung jawab untuk melakukan operasi konvolusi pada data *input*, di mana lapisan ini menggunakan filter atau kernel untuk menghasilkan *feature map* yang menangkap pola-pola penting dari data *input*. *Convolutional layer* memproses informasi spasial dari gambar dan memungkinkan CNN untuk secara otomatis mengekstraksi fitur penting yang diperlukan dalam klasifikasi (Mesárošová *et al.*, 2024).



Gambar 16. Ilustrasi *Convolutional Layer*.

2.6.1.2 Pooling Layer

Pooling layer bertujuan untuk mengurangi dimensi spasial dari *output* lapisan sebelumnya dengan menghitung nilai maksimum pada jendela filter (*max-pooling*) atau rata-rata nilai (*average-pooling*) dalam suatu wilayah tertentu. Proses ini membantu dalam mengurangi kompleksitas komputasi dan memungkinkan lapisan konvolusi berikutnya untuk mengekstraksi fitur pada skala yang berbeda (Mesárošová *et al.*, 2024).




Gambar 17. Ilustrasi *Pooling Layer*.

2.6.2 Classification

Proses klasifikasi pada arsitektur CNN dilakukan setelah lapisan *convolutional* dan *pooling*, di mana lapisan *fully connected* digunakan untuk menghubungkan fitur-fitur yang diekstraksi dengan lapisan *output*. Fungsi aktivasi seperti *Softmax* sering digunakan di lapisan ini untuk menghasilkan nilai probabilitas yang menunjukkan kelas prediksi, sehingga proses klasifikasi dapat berjalan dengan akurat (Mesárošová *et al.*, 2024).

2.7 You Only Look Once v10 (YOLOv10)

YOLOv10 memperkenalkan berbagai inovasi arsitektur yang signifikan untuk meningkatkan kinerja deteksi objek secara *real-time*. Elemen kunci dari YOLOv10 adalah penggunaan strategi *dual label assignments* dalam protokol pelatihannya, yang membantu mengoptimalkan akurasi deteksi tanpa mengorbankan kecepatan. Model ini juga dilengkapi dengan *head classification* ringan yang mengurangi beban komputasi, serta *downsampling spasial* yang terpisah untuk meminimalkan kehilangan informasi selama proses pengurangan fitur. YOLOv10 memastikan penggunaan parameter yang efisien, sehingga model ini dapat beradaptasi di berbagai lingkungan operasional dengan kebutuhan komputasi yang berbeda (Sapkota *et al.*, 2024). Arsitektur YOLOv10 dapat dilihat pada Gambar 18.



Gambar 18. YOLOv10 Architecture (Huynh et al., 2024).

YOLOv10 terbukti sangat efektif dalam deteksi objek yang lebih kompleks seperti kendaraan. Studi komparatif menunjukkan bahwa YOLOv10 unggul dalam mendeteksi kendaraan yang lebih kecil seperti sepeda dan truk, yang sering kali menjadi tantangan dalam aplikasi deteksi kendaraan. YOLOv10 menggunakan teknik *non-maximum suppression* (NMS) yang mengurangi latensi dan meningkatkan efisiensi, menjadikannya sangat cocok untuk aplikasi transportasi cerdas dan sistem mengemudi otonom. Hasil dari analisis ini menyoroti kemampuan YOLOv10 dalam menyeimbangkan antara akurasi dan kecepatan dalam berbagai kondisi lingkungan (Sundaresan Geetha et al., 2024). Varian yang tersedia dalam arsitektur YOLOv10 mencakup YOLOv10n (*nano*), YOLOv10s (*small*), YOLOv10m (*medium*), YOLOv10b (*base*), YOLOv10l (*large*), dan YOLOv10x (*extra large*) yang masing-masing dirancang untuk kebutuhan komputasi dan tingkat akurasi yang berbeda.

2.8 Hyperparameter

Hyperparameter merupakan parameter penting dalam CNN yang harus ditetapkan sebelum pelatihan model. Parameter ini berperan dalam mengatur proses pembelajaran serta mempengaruhi kinerja dan akurasi model. *Hyperparameter* mencakup beberapa parameter umum seperti *batch-size*, *learning rate*, dan jumlah *epoch*. Pemilihan dan pengaturan yang tepat terhadap *hyperparameter* ini sangat krusial untuk mencapai hasil yang optimal, karena masing-masing *hyperparameter* dapat memengaruhi proses ekstraksi fitur, menghindari *overfitting*, mempercepat konvergensi model, dan meningkatkan efisiensi pelatihan (Raiaan *et al.*, 2024).

2.8.1 Epoch

Epoch merupakan jumlah keseluruhan siklus di mana *dataset* dilalui secara penuh selama pelatihan. Penyesuaian jumlah *epochs* sangat penting untuk menghindari *underfitting* atau *overfitting* pada CNN, karena jumlah yang tepat tergantung pada kompleksitas model dan ukuran *dataset*. Parameter *epoch* memiliki peran yang sangat penting untuk memastikan CNN dapat menggeneralisasi dari data pelatihan dengan baik tanpa terlalu terikat pada data tersebut (Raiaan *et al.*, 2024).

2.8.2 Batch-size

Batch-size merupakan jumlah data yang diproses secara bersamaan selama estimasi *gradien*. Pemilihan *batch-size* yang tepat sangat penting dalam pelatihan CNN, karena ukuran *batch-size* yang besar dapat memperlambat konvergensi jaringan, sedangkan ukuran *batch-size* yang kecil dapat menyebabkan gangguan pada jaringan dan menghasilkan performa yang kurang optimal. Ukuran *batch-size* yang kecil antara 16 hingga 64 digunakan karena memberikan hasil yang lebih baik dibandingkan ukuran yang lebih besar (Raiaan *et al.*, 2024).

2.8.3 *Learning Rate*

Learning rate adalah *hyperparameter* umum yang sangat penting karena mempengaruhi seberapa cepat atau lambat model belajar selama pelatihan. *Learning rate* menentukan seberapa besar pembaruan bobot yang dilakukan pada setiap iterasi dalam algoritma *gradient descent*. *Learning rate* terlalu tinggi dapat menyebabkan model berkonvergensi menjadi tidak stabil. *Learning rate* yang terlalu rendah membuat model berkonvergensi dengan sangat lambat, membutuhkan waktu lebih lama untuk dilatih, atau bahkan terjebak dalam *local minima*. Penyetelan *learning rate* yang tepat pada model CNN penting untuk meningkatkan performa pelatihan sekaligus menghasilkan akurasi lebih baik (Raiaan *et al.*, 2024).

2.8.4 *Optimizer*

Optimizer merupakan salah satu elemen penting dalam pelatihan jaringan neural yang berperan dalam mengatur bobot dan laju pembelajaran guna meminimalkan fungsi *loss*. Terdapat berbagai jenis *optimizer* yang digunakan dalam arsitektur CNN, di antaranya *Gradient Descent* (GD), *Stochastic Gradient Descent* (SGD), *Mini-Batch GD*, *Nesterov Accelerated Gradient* (NAG), *Adam*, *Nadam*, *Adamax*, *RMSprop*, dan *Adaptive Gradient* (AdaGrad). Setiap *optimizer* memiliki karakteristik dan keunggulan tersendiri yang dapat disesuaikan dengan kebutuhan *dataset* serta tujuan pelatihan model. Penggunaan *optimizer* yang tepat dapat mempercepat proses konvergensi dan mengoptimalkan kinerja model dalam menghasilkan prediksi yang akurat (Raiaan *et al.*, 2024).

2.9 Anotasi

Anotasi merupakan proses penting dalam pengolahan data visual untuk keperluan pembelajaran mesin. Proses ini dilakukan dengan cara memberikan label atau tanda pada objek yang terdapat dalam gambar. Tujuan utama dari anotasi adalah menyediakan data berlabel yang akurat guna melatih model agar mampu mengenali

dan mengidentifikasi objek secara otomatis. Konteks deteksi objek menggunakan anotasi dengan menandai posisi objek melalui kotak pembatas serta menentukan kelas dari setiap objek tersebut. Hasil dari proses anotasi menghasilkan file berisi data posisi kotak pembatas beserta label objek. Format file menggunakan ekstensi .txt dengan struktur baris yang terdiri atas $\langle object-class \rangle$, $\langle x_center \rangle$, $\langle y_center \rangle$, $\langle width \rangle$, dan $\langle height \rangle$. $\langle object-class \rangle$ merupakan angka bulat yang merepresentasikan kelas objek. $\langle x_center \rangle$ dan $\langle y_center \rangle$ menunjukkan koordinat pusat kotak pembatas. $\langle width \rangle$ dan $\langle height \rangle$ merupakan nilai pecahan desimal yang mewakili ukuran relatif terhadap dimensi gambar (Maleh *et al.*, 2023). Anotasi dalam format YOLO dapat dilihat pada Persamaan (2).

$$Y = \begin{bmatrix} P(Object)_1 \\ c_1 \\ b_{x1} \\ b_{y1} \\ b_{w1} \\ b_{h1} \\ P(Object)_2 \\ c_2 \\ b_{x2} \\ b_{y2} \\ b_{w2} \\ b_{h2} \end{bmatrix} \dots\dots\dots(2)$$

2.10 Computer Vision Annotation Tool (CVAT)


Computer Vision Annotation Tool (CVAT) merupakan perangkat lunak sumber terbuka yang dirancang untuk memfasilitasi proses anotasi gambar dan video. Perangkat ini menyediakan antarmuka pengguna berbasis *web* dan lokal dengan fitur seperti pemilihan bentuk anotasi, pengaturan warna, filter visual, serta ekspor data dalam berbagai format seperti YOLO, PASCAL VOC, dan TFRecord. CVAT dilengkapi alat otomatisasi yang dapat mempercepat pelabelan, serta mendukung penggunaan pintasan untuk efisiensi kerja. CVAT digunakan secara luas sebagai alat dasar dalam berbagai penelitian medis dan kecerdasan buatan, termasuk untuk pelabelan gambar medis yang memerlukan akurasi tinggi (Selnes *et al.*, 2022).

2.11 Intersection over Union (IoU)

Intersection over Union (IoU) adalah metrik yang digunakan untuk mengukur kesesuaian antara prediksi kotak pembatas (*bounding box*) dan area anotasi (*ground truth*) pada deteksi objek. Perhitungan IoU dilakukan dengan membagi luas area yang beririsan antara dua kotak pembatas dengan luas area gabungan kedua kotak tersebut. Nilai IoU mengukur sejauh mana prediksi objek mendekati objek sebenarnya pada *image*. Nilai IoU yang semakin tinggi menunjukkan kesesuaian antara prediksi dengan *ground truth* yang lebih baik. Metrik ini penting dalam evaluasi model deteksi objek berbasis YOLO (Padilla *et al.*, 2021). Perhitungan IoU dapat dilihat pada Persamaan (3).

$$\text{IoU} = \frac{\text{Area Irisan}}{\text{Area Gabungan}} \dots\dots\dots(3)$$

Gambar 19 memperlihatkan ilustrasi perhitungan nilai IoU pada objek kupu-kupu. Nilai IoU merepresentasikan tingkat tumpang tindih antara area prediksi yang dihasilkan oleh model dengan area anotasi sebenarnya atau *ground truth*. Perhitungan dilakukan dengan membagi luas area irisan antara *bounding box* prediksi dan *bounding box ground truth* terhadap luas gabungan kedua area tersebut. Nilai IoU yang semakin besar, menandakan semakin akurat prediksi model dalam mengenali objek pada citra.



Gambar 19. Ilustrasi Deteksi IoU.

2.12 Confusion Matrix

Confusion matrix merupakan alat penting dalam tugas klasifikasi yang memberikan gambaran terperinci tentang kinerja model dengan membandingkan hasil prediksi dengan hasil aktual. Matriks ini terdiri dari empat elemen utama yaitu *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN), yang memberikan wawasan tentang seberapa baik model membedakan antara kelas-kelas yang ada. *Confusion matrix* digunakan untuk menghitung metrik evaluasi seperti *precision*, *recall*, *f1-score*, dan *average precision*. Memvisualisasikan empat elemen utama *confusion matrix* dapat membantu untuk mengidentifikasi area di mana model berkinerja baik dan area yang memerlukan perbaikan, menjadikannya langkah penting dalam evaluasi dan penyempurnaan algoritma klasifikasi (Ahad *et al.*, 2023). Tabel *confusion matrix* dapat dilihat pada Tabel 2.

Tabel 2. *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 tabel:

- 1) *True Positive* (TP) : Jumlah data yang bernilai positif dan diprediksi benar sebagai positif
- 2) *False Negative* (FN) : Jumlah data yang bernilai positif tetapi diprediksi sebagai negatif
- 3) *False Positive* (FP) : Jumlah data yang bernilai negatif tetapi diprediksi sebagai positif
- 4) *True Negative* (TN) : Jumlah data yang bernilai negatif dan diprediksi benar sebagai negatif

Perhitungan metrik evaluasi yang digunakan sebagai berikut:

2.12.1 Precision

Metrik *precision* merupakan metrik evaluasi sistem klasifikasi yang mengukur seberapa akurat prediksi positif model. *Precision* dihitung sebagai rasio antara *true positive* dan total prediksi positif, termasuk yang salah. Metrik ini penting untuk memastikan prediksi positif yang tepat, terutama dalam situasi di mana kesalahan prediksi positif dapat berdampak besar, sehingga meminimalkan *false positive* (Yang, 1999). Perhitungan *precision* dapat dilihat pada Persamaan (4).

$$Precision = \frac{TP}{TP+FP} \times 100\% \dots\dots\dots(4)$$

2.12.2 Recall

Metrik *recall* digunakan untuk menilai seberapa baik model dalam mendeteksi seluruh data positif yang sebenarnya. Perhitungan *recall* didasarkan pada rasio antara jumlah *true positives* dengan total data positif, termasuk yang tidak terdeteksi oleh model (*false negative*). Nilai *recall* menunjukkan kemampuan model dalam menemukan semua kasus positif, yang sangat penting dalam situasi untuk meminimalkan kesalahan *false negative*. Metrik ini memastikan bahwa model mampu mengidentifikasi semua data yang relevan dalam kategori positif (Yang, 1999). Perhitungan *recall* dapat dilihat pada Persamaan (5).

$$Recall = \frac{TP}{TP+FN} \times 100\% \dots\dots\dots(5)$$

2.12.3 F1-score

Metrik *f1-score* digunakan untuk menyeimbangkan *precision* dan *recall* dalam evaluasi model klasifikasi. *F1-score* memberikan gambaran yang lebih adil sebagai rata-rata harmonis dari kedua metrik, terutama ketika *precision* dan *recall* berbeda secara signifikan. Metrik ini penting saat keseimbangan antara ketepatan prediksi positif dan kemampuan mendeteksi semua data positif menjadi prioritas (Yang, 1999). Perhitungan *f1-score* dapat dilihat pada Persamaan (6).

$$F1-score = \frac{2 \times P \times R}{P + R} \times 100\% \dots\dots\dots(6)$$

2.12.4 Average Precision (AP)

Average Precision (AP) adalah metrik evaluasi yang digunakan untuk mengukur kinerja algoritma deteksi objek dengan menghitung area di bawah kurva *Precision-Recall* yang telah diinterpolasi untuk menghilangkan sifat *zig-zag* dari kurva asli. Metrik ini mengintegrasikan *precision* dan cakupan deteksi objek pada berbagai tingkat kepercayaan (*confidence levels*) dengan memanfaatkan IoU sebagai ukuran kesesuaian antara kotak deteksi dengan *ground truth* (Padilla *et al.*, 2021). Perhitungan AP dapat dilihat pada Persamaan (7).

$$AP = \sum_n (R_{n+1} - R_n) P_{interp}(R_{n+1}) \dots \dots \dots (7)$$

2.13 mean Average Precision (mAP)

mean Average Precision (mAP) merupakan metrik evaluasi untuk mengukur performa model deteksi objek berdasarkan kedekatan prediksi *bounding box* terhadap *ground truth*. Perhitungan mAP dilakukan dengan menghitung rata-rata AP dari setiap kelas objek. Nilai AP dihitung melalui analisis kurva *precision-recall*. Evaluasi ini menggunakan IoU sebagai indikator kesesuaian area prediksi terhadap area sebenarnya dengan nilai ambang tertentu, seperti 0.5 atau 0.75 (Fandisyah *et al.*, 2021). Perhitungan mAP dapat dilihat pada Persamaan (8).

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \dots \dots \dots (8)$$

2.14 Overfitting

Overfitting merupakan kondisi ketika model *deep learning* memiliki akurasi tinggi pada data pelatihan namun gagal memberikan hasil yang baik saat diujikan pada data baru. Model yang mengalami *overfitting* cenderung menangkap pola yang tidak relevan atau *noise* dari data pelatihan, sehingga kehilangan kemampuan generalisasi terhadap data aktual. Pada konteks *side-channel analysis* berbasis *deep learning*, *overfitting* menjadi hambatan signifikan dalam memperoleh model yang

optimal dan akurat. Masalah ini sering terjadi karena banyaknya parameter pada model serta kompleksitas data yang tinggi. Regularisasi menjadi salah satu pendekatan yang digunakan untuk mengatasi *overfitting* dengan cara mengontrol kompleksitas model dan mencegah pembelajaran berlebih terhadap data pelatihan. Penelitian menunjukkan bahwa teknik regularisasi seperti L1, L2, *dropout*, dan *early stopping* dapat meningkatkan performa model dalam banyak kasus, dengan L1 dan L2 terbukti paling efektif dalam meningkatkan generalisasi model (Rezaeezade & Batina, 2024).

2.15 *Underfitting*

Underfitting merupakan kondisi ketika model *deep learning* gagal mempelajari pola yang terdapat dalam data pelatihan sehingga menghasilkan performa prediksi yang rendah pada data pelatihan maupun data pengujian. Masalah ini muncul akibat arsitektur model yang terlalu sederhana atau jumlah *epoch* pelatihan yang tidak mencukupi. Model yang mengalami *underfitting* memiliki *error* yang tinggi dan tidak mampu menangkap hubungan kompleks antar fitur dalam data. Dalam konteks *deep learning-based side-channel analysis*, *underfitting* terjadi ketika model tidak mampu mendeteksi distribusi kebocoran informasi yang relevan dari *measurement traces*. Kondisi ini berbeda dengan *overfitting* karena kesalahan terjadi pada tahap pembelajaran awal. Penelitian menjelaskan bahwa untuk mengatasi *underfitting*, salah satu pendekatan yang umum digunakan adalah meningkatkan kompleksitas model, seperti menambah jumlah neuron, *hidden layer*, atau memperpanjang durasi pelatihan agar model dapat mencapai akurasi optimal (Rezaeezade & Batina, 2024).

III. METODOLOGI PENELITIAN

3.1 Waktu dan Tempat

Waktu dan tempat penelitian ini ditetapkan sebagai berikut:

3.1.1 Waktu Penelitian

Penelitian ini dilakukan pada bulan Oktober tahun ajaran 2024/2025 sampai dengan bulan Mei tahun ajaran 2024/2025. Waktu penelitian akan dijelaskan dengan tabel *gantt chart* pada Tabel 3.

Tabel 3. Rencana Penelitian

Kegiatan	2024												2025																			
	Okt				Nov				Des				Jan				Feb				Mar				Apr				Mei			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV				
Pengumpulan <i>Dataset</i>																																
<i>Preprocessing</i>																																
Anotasi Data																																
<i>Splitting</i> Data																																
<i>Training</i> Arsitektur																																
Evaluasi Arsitektur																																

3.1.2 Tempat Penelitian

Penelitian ini dilaksanakan di dua lokasi utama, yaitu di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung dan Batik Siger, sebuah umkm yang bergerak di bidang produksi dan pemasaran kain batik khas Lampung. Batik Siger berlokasi di Jalan Bayam No. 38, Kelurahan Beringin Raya, Kecamatan Kemiling, Kota Bandar Lampung.

3.2 Alat dan Bahan

Alat dan bahan yang dibutuhkan dalam penelitian ini sebagai berikut:

3.2.1 Alat Penelitian

Penelitian ini membutuhkan beberapa peralatan yang akan mendukung jalannya proses penelitian. Peralatan yang diperlukan meliputi perangkat lunak (*software*) dan perangkat keras (*hardware*).

3.2.1.1 Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan untuk mendukung proses identifikasi motif batik Lampung meliputi sistem operasi *Windows 11 Pro 64-bit*, *CVAT*, *Vast.AI*, *Python* versi 3.10, *Jupyter Notebook*, *Library os* untuk manajemen file, *Library cv2* untuk pemrosesan citra, *Library MultilabelStratifiedShuffleSpli* untuk pembagian *dataset* secara proporsional, *Library ultralytics* untuk pelatihan arsitektur YOLOv10, dan *Library time* untuk mengukur durasi proses.


3.2.1.2 Perangkat Keras (*Hardware*)

Perangkat keras untuk pengambilan *dataset* motif batik Lampung menggunakan kamera Canon EOS 250D dengan pengaturan ISO 400, *focal length* 50mm, resolusi Full HD 1920x1080 piksel. Perangkat keras untuk mendukung proses identifikasi motif batik Lampung terdiri atas komputer dengan GPU NVIDIA RTX 4090 dan laptop Asus TUF Gaming FX505DD dengan spesifikasi RAM 8 GB, SSD 500 GB, GPU NVIDIA GTX 1050, serta prosesor AMD Ryzen 5 3550H.

3.2.2 Bahan Penelitian

Penelitian ini menggunakan 14 video rekaman berdurasi 20 detik yang menampilkan motif batik Lampung secara detail. Video diambil secara langsung dari batik Siger menggunakan kamera dengan kualitas yang cukup baik untuk memastikan visual motif terekam dengan jelas dan akurat.

3.3 Alur Penelitian



Gambar 20. Alur Penelitian.

Alur penelitian yang akan dilakukan dapat dilihat pada Gambar 20 dengan penjelasan sebagai berikut:

3.3.1 Pengumpulan *Dataset*

Tahap awal penelitian melibatkan pengumpulan data berupa 14 rekaman video motif batik Lampung dengan durasi masing-masing 20 detik menggunakan latar dan pencahayaan yang seragam. Seluruh rekaman kemudian digabungkan menjadi satu video berdurasi 40 detik. Video berdurasi 40 detik ini menampilkan 14 motif batik yang terbagi ke dalam empat segmen waktu. Detik 1–10 memuat motif batik Abstrak, Kambil Sicukil, Adiwarna, dan Kupi. Detik 11–20 menampilkan motif Granitan, Kembang Cengkih, dan Jung Agung. Detik 21–30 memuat motif Siger Ratu Agung, Sinaran, Tambal, dan Liman. Detik 31–40 menampilkan motif Sekar Jagat, Sembagi, dan Menara Siger.

3.3.2 *Preprocessing*

Preprocessing dilakukan melalui tiga tahap utama. Tahap pertama berupa augmentasi video menggunakan berbagai metode seperti *speed*, *wave*, *brightness*, *zoom in*, *zoom out*, dan *flip*. Tahap kedua berupa ekstraksi video hasil augmentasi menjadi *frame* dalam format JPG. Ekstraksi dilakukan dengan membagi setiap detik video menjadi sejumlah *frame* tetap untuk memastikan seluruh motif batik terekam secara merata. Tahap ketiga berupa perubahan ukuran citra hasil ekstraksi menjadi 640×640 piksel, kemudian disimpan ke dalam direktori khusus untuk diproses di lingkungan komputasi vast.ai dalam menunjang tahap pelatihan model.

3.3.3 *Anotasi Data*

Proses anotasi dilakukan dengan memberikan kategori atau label pada setiap elemen data citra yang telah dikumpulkan sebelumnya. Kategori tersebut berfungsi sebagai informasi penanda yang dapat dimanfaatkan oleh model *deep learning* dalam mengenali serta membedakan objek saat proses pelatihan. Setiap objek diberi anotasi berupa *bounding box* yang mencakup informasi tentang kelas objek, posisi, dan ukuran *bounding box* terhadap citra. Anotasi data penelitian ini dilakukan dengan menggunakan *platform* CVAT untuk memudahkan proses penandaan objek secara manual pada data citra.

3.3.4 *Splitting Data*

Data penelitian dibagi menjadi tiga kelompok utama, yaitu data pelatihan (*training*), data validasi (*validation*), dan data pengujian (*test*). Penelitian ini menggunakan proporsi 70% untuk data pelatihan, 15% untuk data validasi, dan 15% untuk data pengujian. Pembagian data dilakukan untuk memastikan ketersediaan data yang cukup dalam proses pelatihan model, validasi yang optimal untuk menyempurnakan parameter model, serta pengujian yang komprehensif dalam mengevaluasi kinerja akhir model secara keseluruhan.

3.3.5 Training Arsitektur

Proses pelatihan dilakukan menggunakan seluruh varian arsitektur YOLOv10 dan diimplementasikan melalui layanan *cloud computing vast.ai*, sehingga memungkinkan pemrosesan komputasi secara efisien. Sebanyak 1200 citra motif batik Lampung digunakan dalam penelitian ini setelah melalui proses *preprocessing* dan menghasilkan total 4143 *bounding box* dari hasil anotasi data yang telah dilakukan sebelumnya. Pelatihan model memanfaatkan sejumlah *hyperparameter* umum seperti *epoch*, *batch size*, *learning rate*, dan *optimizer* yang disesuaikan untuk mengoptimalkan kinerja model. Rincian konfigurasi *hyperparameter* yang digunakan dapat dilihat pada Tabel 4.

Tabel 4. Konfigurasi *Hyperparameter*

<i>Hyperparameter</i>	Nilai
<i>Epoch</i>	50
<i>Batch-size</i>	16
<i>Learning-rate</i>	0,001
<i>Optimizer</i>	SGD
<i>Patience</i>	5

Setiap varian model dalam penelitian ini menggunakan kombinasi *hyperparameter* yang seragam untuk memastikan perbandingan yang adil. Penentuan nilai *epoch*, *batch-size*, *learning rate*, dan *optimizer* mengacu pada beberapa literatur jurnal yang relevan dengan penelitian ini. Strategi *early stopping* diterapkan menggunakan *patience*, yaitu penghentian pelatihan otomatis ketika tidak terjadi peningkatan performa dalam sejumlah *epoch* tertentu, guna mencegah *overfitting* dan meningkatkan efisiensi pelatihan.

3.3.6 Evaluasi Arsitektur

Proses evaluasi dilakukan untuk mengukur performa dan efisiensi model. Tingkat akurasi model dianalisis melalui perhitungan nilai IoU, yang membandingkan kotak prediksi dengan kotak pembatas yang sesungguhnya. Nilai IoU digunakan bersama dengan *confusion matrix* untuk menghitung *precision*, *recall*, *f1-score*, *average precision*, dan mAP. Efisiensi diukur berdasarkan kecepatan proses inferensi dan waktu yang dibutuhkan model untuk proses identifikasi motif batik Lampung.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Hasil penelitian menunjukkan bahwa varian YOLOv10l memberikan performa terbaik dengan nilai mAP@50 sebesar 0,9244 (92,44%) serta nilai *precision*, *recall*, dan *f1-score* yang tinggi pada seluruh kelas motif. Varian ini juga mencatat rata-rata IoU tinggi yang mencerminkan presisi deteksi unggul. Efisiensi pemrosesan ditunjukkan oleh varian YOLOv10s dengan waktu proses tercepat sebesar 2,03 menit dan FPS tertinggi sebesar 88,12. Hasil analisis secara keseluruhan merekomendasikan YOLOv10l untuk kebutuhan deteksi dengan akurasi tinggi, sementara YOLOv10s lebih sesuai untuk implementasi sistem *real-time* yang menuntut efisiensi komputasi tanpa mengorbankan akurasi secara signifikan.

5.2 Saran

Saran yang diberikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Uji coba model pada berbagai perangkat keras, seperti GPU dengan spesifikasi berbeda untuk mengetahui performa model dalam berbagai lingkungan komputasi dan menentukan konfigurasi optimal berdasarkan kebutuhan sistem.
2. Penerapan arsitektur YOLOv10 untuk aplikasi *mobile* dapat menjadi pengembangan lebih lanjut yang memungkinkan identifikasi motif batik Lampung secara *real-time* melalui perangkat seluler.

DAFTAR PUSTAKA

- Ahad, M. T., Li, Y., Song, B., & Bhuiyan, T. (2023). Comparison of CNN-based deep learning architectures for rice diseases classification. *Artificial Intelligence in Agriculture*, 9, 22–35. <https://doi.org/10.1016/j.aiia.2023.07.001>
- 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>
- Andrian, R., Herwanto, H. C., Taufik, R., & Kurniawan, D. (2024). Performance comparison between LeNet and MobileNet in convolutional neural network for Lampung batik image identification. *Scientific Journal of Informatics*, 11(1), 147–154. <https://doi.org/10.15294/sji.v11i1.49451>
- 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), 1–6. <https://doi.org/10.1088/1742-6596/1338/1/012061>
- Armelia, R. D., Andrian, R., & Junaidi, A. (2024). Perbandingan kinerja backpropagation dan convolutional neural network untuk klasifikasi citra batik Lampung. *Jurnal Komputasi*, 12(1), 11–18. <https://doi.org/10.23960/komputasi.v12i1.248>
- Awaluddin, B.-A., Chao, C.-T., & Chiou, J.-S. (2023). Investigating effective geometric transformation for image augmentation to improve static hand gestures with a pre-trained convolutional neural network. *Mathematics*, 11(23), 1–23. <https://doi.org/10.3390/math11234783>

- Fandisyah, A. F., Iriawan, N., & Winahju, W. S. (2021). Deteksi kapal di laut Indonesia menggunakan YOLOv3. *Jurnal Sains Dan Seni ITS*, 10(1), 25–32. <https://doi.org/10.12962/j23373520.v10i1.59312>
- Hendrawati, S., Ramadhan, R., Chaerunisa, N., & Limayucha, S. A. (2021). Pengenalan perkembangan batik Tedjo di era globalisasi. *Indonesian Collaboration Journal of Community Services (ICJCS)*, 1(4), 185–196. <https://doi.org/10.53067/icjcs.v1i4.30>
- Hinton, G. E., Osindero, S., & Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527–1554. <https://doi.org/10.1162/neco.2006.18.7.1527>
- Huynh, T. T., Nguyen, H. T., & Phu, D. T. (2024). Enhancing fire detection performance based on fine-tuned YOLOv10. *Computers, Materials & Continua*, 81(2), 2281–2298. <https://doi.org/10.32604/cmc.2024.057954>
- Kusumanto, R. D., & Tompunu, A. N. (2011). Pengolahan citra digital untuk mendeteksi obyek menggunakan pengolahan warna model normalisasi RGB. *Seminar Nasional Teknologi Informasi & Komunikasi Terapan*, 1(1), 1–7. <https://repository.dinus.ac.id/docs/jurnas/15151.pdf>
- Le Cun Jackel, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, L. D., Cun, B. Le, Denker, J., & Henderson, D. (1989). *Handwritten digit recognition with a back-propagation network*. 396–404. <https://proceedings.neurips.cc/paper/1989/file/53c3bce66e43be4f209556518c2fcb54-Paper.pdf>
- Maleh, I. M. D., Teguh, R., Sahay, A. S., Okta, S., & Pratama, M. P. (2023). Implementasi algoritma You Only Look Once (YOLO) untuk object detection sarang orang utan di taman nasional Sebangau. *Jurnal Informatika*, 10(1), 19–27. <https://doi.org/10.31294/inf.v10i1.13922>
- 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), 1–22. <https://doi.org/10.3390/rs13132591>

- Mesárošová, M., Mihálik, O., & Jirgl, M. (2024). CNN architecture for posture classification on small data. *IFAC-PapersOnLine*, 58(9), 299–304. <https://doi.org/10.1016/j.ifacol.2024.07.413>
- Padilla, R., Passos, W. L., Dias, T. L. B., Netto, S. L., & da Silva, E. A. B. (2021). A comparative analysis of object detection metrics with a companion open-source toolkit. *Electronics*, 10(3), 1–28. <https://doi.org/10.3390/electronics10030279>
- Putri, A. R. (2016). Pengolahan citra dengan menggunakan web cam pada kendaraan bergerak di jalan raya. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 1(01), 1–6. <https://doi.org/10.29100/jipi.v1i01.18>
- Raiaan, M. A. K., Sakib, S., Fahad, N. M., Mamun, A. Al, Rahman, M. A., Shatabda, S., & Mukta, M. S. H. (2024). A systematic review of hyperparameter optimization techniques in convolutional neural networks. *Decision Analytics Journal*, 11, 1–32. <https://doi.org/10.1016/j.dajour.2024.100470>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, real-time object detection. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016-Decem, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Rezaeezade, A., & Batina, L. (2024). Regularizers to the rescue: fighting overfitting in deep learning-based side-channel analysis. *Journal of Cryptographic Engineering*, 14(4), 609–629. <https://doi.org/10.1007/s13389-024-00361-5>
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386–408. <https://doi.org/10.1037/h0042519>
- Sapkota, R., Calero, M. F., Qureshi, R., Badgujar, C., Nepal, U., Poullose, A., Zeno, P., Vaddevolu, U. B. P., Khan, S., Shoman, M., Yan, H., & Karkee, M. (2024). YOLO advances to its genesis: a decadal and comprehensive review of the You Only Look Once (YOLO) series. *Artif Intell Rev*, 58(9), 1–49. <https://doi.org/10.1007/s10462-025-11253-3>

- Selnes, O., Bjørsum-Meyer, T., Histace, A., Baatrup, G., & Koulaouzidis, A. (2022). Annotation tools in gastrointestinal polyp annotation. *Diagnostics*, 12(10), 1–10. <https://doi.org/10.3390/diagnostics12102324>
- Sundaresan Geetha, A., Alif, M. A. R., Hussain, M., & Allen, P. (2024). Comparative analysis of YOLOv8 and YOLOv10 in vehicle detection: Performance metrics and model efficacy. *Vehicles*, 6(3), 1364–1382. <https://doi.org/10.3390/vehicles6030065>
- Uswatun Khasanah, C., Utami, E., & Raharjo, S. (2020). Implementation of data augmentation using convolutional neural network for batik classification. *2020 8th International Conference on Cyber and IT Service Management (CITSM)*, 1–5. <https://doi.org/10.1109/CITSM50537.2020.9268890>
- Venkatesan, K., Muthulakshmi, M., Prasanalakshmi, B., Karthickeien, E., Pabbisetty, H., & Syarifah Bahiyah, R. (2025). Comparative analysis of resource-efficient YOLO models for rapid and accurate recognition of intestinal parasitic eggs in stool microscopy. *Intelligence-Based Medicine*, 11, 1–16. <https://doi.org/10.1016/j.ibmed.2025.100212>
- Yang, Y. (1999). An evaluation of statistical approaches to text categorization. *Information Retrieval*, 1(1–2), 69–90. <https://doi.org/10.1023/A:1009982220290>