

# Implementasi *Deep Learning* Model untuk Deteksi dan Klasifikasi *Real-time* Motif Khas Toraja (Pa'ssura') sebagai Upaya Pelestarian Budaya Digital

## *Implementation of a Deep Learning Model for Real-Time Detection and Classification of Toraja Traditional Motifs (Pa'ssura') for Digital Cultural Preservation*

<sup>1</sup>Ali Asgar Zainal Abidin\*, <sup>2</sup>Mursyid Ardiansyah, <sup>3</sup>Aqilah Zahra

<sup>1,2</sup>Program Studi Ilmu Komputer, Departemen Teknologi dan Bisnis, Institut Teknologi Sains dan Bisnis Muhammadiyah Selayar

<sup>3</sup>Program Studi Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Alauddin Makassar

<sup>1,2</sup>Jl. R.A. Kartini No. 17, Benteng, Benteng, Kepulauan Selayar, Sulawesi Selatan, Indonesia

<sup>3</sup>Jl. Sultan Alauddin No. 63, Romangpolong, Somba Opu, Gowa, Sulawesi Selatan, Indonesia

\*e-mail: [aliasgarzainalabidin@gmail.com](mailto:aliasgarzainalabidin@gmail.com)

(received: 4 February 2026, revised: 18 April 2026, accepted: 19 April 2026)

### Abstrak

Motif khas Toraja atau Pa'ssura' adalah warisan budaya tak benda yang kaya akan nilai filosofi dan identitas kultural yang mendalam. Namun, orisinalitas dan pemahaman makna di balik setiap motif tersebut menghadapi resiko erosi di kalangan generasi muda akibat minimnya media pembelajaran yang interaktif dan relevan dengan perkembangan teknologi digital. Penelitian ini bertujuan untuk menjembatani kesenjangan tersebut melalui strategi pelestarian budaya digital yang inovatif dengan mengimplementasikan teknologi *deep learning*. Secara spesifik, penelitian ini berfokus pada pengembangan sistem deteksi dan klasifikasi objek secara *real-time* menggunakan arsitektur *Convolutional Neural Network* (CNN), khususnya model YOLO11s. Tahapan utama riset mencakup pembangunan dataset citra beranotasi untuk tujuh motif utama Pa'ssura' yaitu Pa' Barre Allo, Pa' Kapu Baka, Pa' Tangke Lumu, Pa' Tedong, Pa' Ulu Karua, Pa' Kadang Pao dan Pa' Papan Kandaure yang diambil dari berbagai *planar* seperti kain dan media *non planar* meliputi ukiran kayu, dan pahatan batu. Hasil penelitian menunjukkan bahwa model yang dikembangkan berhasil mencapai tingkat presisi sebesar 0,7109, recall sebesar 0,6708, dan mAP<sub>50</sub> sebesar 0,6910 setelah melalui proses pelatihan selama 100 epoch. Implementasi teknik augmentasi data terbukti efektif dalam meningkatkan jumlah dataset. Jumlah dataset sebelum augmentasi berjumlah 1050 citra dan setelah augmentasi menjadi 2520 citra, yang secara signifikan memperkuat ketangguhan model dalam deteksi dan klasifikasi pada media *planar* maupun media *non planar*. Melalui penelitian ini menghasilkan model yang akurat dan aplikatif sebagai media edukasi pada aplikasi *mobile*. Model ini juga berperan penting dalam melestarikan warisan budaya Toraja melalui digitalisasi.

**Kata kunci:** *computer vision, deep learning, pa'ssura'*, pelestarian budaya digital, YOLO11s

### Abstract

*Toraja traditional motifs, known as Pa'ssura', represent an intangible cultural heritage rich in philosophical values and deep cultural identity. However, the authenticity and understanding of the meanings behind these motifs are at risk of erosion among younger generations due to the lack of interactive and technologically relevant learning media. This study aims to bridge this gap through an innovative digital cultural preservation strategy by implementing deep learning technology. Specifically, the research focuses on developing a real-time object detection and classification system using a Convolutional Neural Network (CNN) architecture, particularly the YOLO11s model. The main research stages include constructing an annotated image dataset for seven primary Pa'ssura' motifs: Pa' Barre Allo, Pa' Kapu Baka, Pa' Tangke Lumu, Pa' Tedong, Pa' Ulu Karua, Pa' Kadang*

<http://sistemasi.ftik.unisi.ac.id>

*Pao, and Pa' Papan Kandaure. These data were collected from both planar media (such as textiles) and non-planar media, including wood carvings and stone engravings. The results show that the developed model achieved a precision of 0.7109, a recall of 0.6708, and an mAP@50 of 0.6910 after 100 training epochs. The implementation of data augmentation techniques proved effective in increasing the dataset size—from 1,050 images before augmentation to 2,520 images after augmentation—thereby significantly enhancing the model's robustness in detecting and classifying motifs across both planar and non-planar media. This study produces an accurate and practical model that can be applied as an educational tool in mobile applications. Furthermore, the model plays an important role in preserving Toraja cultural heritage through digitalization.*

**Keywords:** computer vision, deep learning, digital cultural preservation, pa'ssura', YOLO11s

## 1 Pendahuluan

Warisan budaya merupakan pilar identitas sebuah bangsa. Di Tana Toraja, Sulawesi Selatan, warisan ini terwujud dalam Pa'ssura', seni ukir dan motif khas yang tidak hanya berfungsi sebagai ornamen estetis, tetapi juga sebagai medium penyampaian nilai filosofi, status sosial dan tatanan kosmologi masyarakat Toraja [1]. Setiap goresan pada dinding rumah adat Tongkonan, kuburan batu, atau selembur kain tenun adalah representasi dari kearifan lokal yang diwariskan turun-temurun. Namun, di tengah arus globalisasi dan transformasi digital, terjadi sebuah disrupsi kultural [2]. Pengetahuan mendalam mengenai makna dan ragam Pa'ssura' menghadapi ancaman erosi, terutama di kalangan generasi muda yang interaksinya lebih dominan dengan media digital.

Pa'ssura' atau Motif Toraja memiliki kesulitan dalam mendeteksi pola atau motif yang ada. Hal ini disebabkan karena motif yang ada, tidak hanya berada pada kain atau media datar pada umumnya seperti media kayu yang dicat membentuk motif. Tetapi, pengaplikasian motif tersebut dilakukan dengan cara diukir pada media kayu ataupun batu seperti pada Pemakaman Londa [3]. Tentunya terdapat berbagai macam tantangan saat melakukan identifikasi pada media tersebut, diantaranya kayu yang bertekstur atau lapuk dan batu yang berlumut [4].

Untuk mengatasi permasalahan yang dihadapi, salah satu metode yang dapat digunakan adalah penggunaan teknologi seperti *Computer Vision*. Integrasi kecerdasan buatan dalam bidang ini diharapkan dapat mengatasi kesenjangan antara kekayaan budaya fisik dan minimnya representasi digital yang interaktif, yang saat ini menjadi isu penting. Adapun upaya pelestarian yang dilakukan saat ini, seperti dokumentasi dalam bentuk foto statis atau teks deskriptif di buku dan situs web, sering kali bersifat pasif dan kurang mampu menarik minat audiens modern. Di sisi lain, kemajuan pesat dalam bidang kecerdasan buatan (*Artificial Intelligence*), khususnya *Computer Vision*, membuka peluang revolusioner untuk menjembatani kesenjangan ini. Teknologi ini memungkinkan mesin untuk “melihat” dan “memahami” konten visual layaknya manusia, menawarkan potensi untuk menciptakan interaksi baru antara manusia dengan warisan budayanya [5]. Berbagai penelitian terdahulu telah membuktikan keberhasilan pemanfaatan AI untuk klasifikasi, regresi dan deteksi objek pada batik [6], [7], [8], [9], [10]. Integrasi pada aplikasi *mobile* juga sudah dilakukan dengan menggunakan algoritma EfficientNet sebagai algoritma deteksi objek [11]. Penelitian fundamental ini berangkat dari asumsi bahwa implementasi model *deep learning* dapat menjadi dasar untuk formulasi konsep baru dalam pelestarian budaya digital yang aktif dan partisipatif.

Pemilihan arsitektur *You Only Look Once* (YOLO) dalam penelitian ini didasarkan pada kemampuannya dalam melakukan deteksi objek secara *real-time* tanpa mengorbankan akurasi secara signifikan [12]. Keunggulan kecepatan inferensi, sangat krusial dalam mewujudkan konsep pelestarian digital yang partisipatif. Dengan kemampuan *real-time*, teknologi ini tidak hanya membantu melakukan identifikasi pada motif yang ada. Namun juga sebagai alat bantu edukasi interaktif. Pengguna, khususnya generasi muda dan wisatawan, dapat lebih mudah dalam mengakses informasi yang akurat dan cepat, sesuai kondisi yang terjadi di lapangan.

Penelitian ini akan berfokus pada optimasi model terhadap tujuh motif Pa'ssura' [1]. Dengan menggabungkan pendekatan etnoinformatika dan teknik *Computer Vision* terkini, riset ini diharapkan tidak hanya menghasilkan bukti fungsional tetapi juga memberikan kontribusi teoritis mengenai metodologi deteksi objek budaya pada media *planar* maupun *non planar*. Hal ini menjadi bagian dari

upaya besar dalam membangun ekosistem warisan budaya digital Indonesia yang lebih cerdas, adaptif dan berkelanjutan.

## 2 Tinjauan Literatur

Penelitian terkait pelestarian budaya digital umumnya berfokus pada digitalisasi arsip, pemodelan 3D, dan *virtual reality* museum, yang cenderung bersifat pasif. Dibanding *computer vision*, riset pengenalan motif budaya telah banyak dilakukan, terutama untuk Batik.

Penelitian terdahulu telah mengeksplorasi penggunaan karakteristik geometris seperti simetri untuk mendeskripsikan objek pada motif batik secara efisien. Pendekatan ini memanfaatkan transformasi linear dalam ruang Euclidean, seperti translasi dan rotasi, untuk menentukan jumlah objek melalui algoritma simetri hierarkis. Meskipun terdapat tantangan berupa ketidaksesuaian sumbu simetri akibat kompleksitas karakteristik motif, penambahan aturan spesifik pada deteksi garis simetri terbukti mampu meningkatkan akurasi rata-rata deteksi objek secara signifikan dari 66,21% menjadi 86,19% [13].

Selain aspek teknis, urgensi pelestarian batik didorong oleh tantangan dalam memahami makna filosofis yang terkandung dalam setiap simbol dan ilustrasinya. Kurangnya pemahaman masyarakat terhadap kearifan lokal tersebut menuntut adanya solusi berbasis teknologi informatika dan multimedia. Implementasi metode pengenalan pola dalam pembangunan sistem informasi deteksi motif menjadi krusial untuk menyediakan akses informasi yang akurat dan cepat, terutama bagi pengguna awam, sehingga nilai warisan budaya nusantara dapat terus terjaga [14].

Keberagaman motif batik di Indonesia menuntut adanya sistem klasifikasi citra yang mampu mengidentifikasi karakteristik pola secara akurat. Penggunaan algoritma *Convolutional Neural Network* (CNN) sebagai teknik *Deep Learning* menunjukkan hasil yang paling signifikan dalam pengenalan citra dibandingkan model konvensional. Melalui perbandingan dengan model VGG16, arsitektur CNN terbukti mampu mencapai tingkat akurasi hingga 98% dengan waktu pemrosesan yang lebih efisien, sehingga dinilai sangat efektif untuk mengklasifikasi variasi jenis batik yang luas [15].

Upaya memperkenalkan warisan budaya batik kepada generasi milenial dan audiens internasional dilakukan melalui pengembangan sistem klasifikasi berbasis website. Dengan memanfaatkan teknologi *Machine Learning* berbasis CNN, sistem ini mampu mengklasifikasikan jenis batik berdasarkan ciri-ciri spesifik seperti corak, warna, dan bentuk secara interaktif. Hasil pengujian menunjukkan bahwa model *Deep Learning* tersebut berhasil mencapai tingkat akurasi sebesar 91,24% pada data pengujian, yang mengukuhkan efektivitas platform digital dalam memperkenalkan kekayaan budaya secara lebih luas [16].

Otomatisasi identifikasi motif batik melalui pendekatan *multi-class classification* menggunakan CNN menjadi fokus utama untuk menangani kekayaan variasi motif yang ada. Pengembangan model ini menekankan pada pentingnya teknik pra-pemrosesan data dan augmentasi citra guna meningkatkan keterampilan serta ketangguhan model dalam mengenali pola-pola yang beragam. Evaluasi menggunakan metrik klasifikasi memberikan wawasan mendalam mengenai faktor-faktor yang mempengaruhi keputusan model, yang pada akhirnya berkontribusi terhadap upaya pelestarian seni budaya Indonesia melalui teknologi otomatisasi [17].

Penerapan *Deep Learning* juga telah diuji pada motif batik daerah yang sangat spesifik, seperti Batik Sasambo asal Nusa Tenggara Barat. Dengan memanfaatkan jaringan syaraf tiruan melalui metode CNN, pengenalan pola dilakukan terhadap kategori motif lokal seperti peresean, bunga aruna, dan kangkung. Penggunaan arsitektur dengan empat *layer* konvolusi pada dataset terbatas menunjukkan performa yang cukup baik dengan tingkat akurasi pengujian sebesar 80%, membuktikan fleksibilitas CNN dalam menyelesaikan permasalahan *object detection* dan *image classification* pada motif etnik yang unik [18].

Ketergantungan pada pengetahuan ahli dalam klasifikasi manual dinilai tidak efisien, sehingga mendorong transisi menuju pendekatan *data-driven* berbasis CNN yang lebih objektif. Melalui pemanfaatan teknik *transfer learning* dengan model *pre-trained* MobileNetV3, klasifikasi otomatis terhadap pola-pola kompleks seperti Kawung, Lereng, dan Parang dapat dilakukan dengan akurasi tinggi. Penggunaan dataset yang lebih besar mencapai 4.284 citra serta teknik augmentasi data memungkinkan model mencapai akurasi pengujian sebesar 93,88%, yang memberikan fondasi kuat bagi digitalisasi industri batik dan kemajuan teknologi berbasis kecerdasan buatan

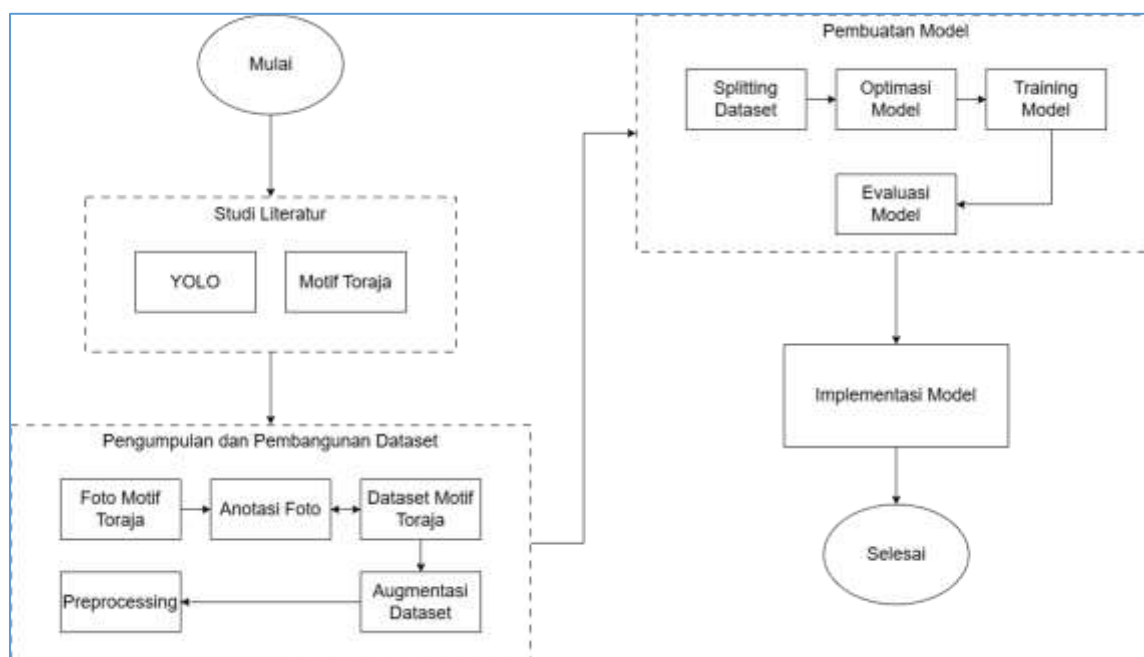
Berbagai arsitektur CNN modern telah dieksplorasi untuk meningkatkan akurasi, seperti EfficientNet [11], VGG16 [19], MobileNet [20], hingga pendekatan *ensemble learning* untuk meningkatkan kekokohan klasifikasi [21]. Beberapa penelitian juga menekankan pentingnya peran ahli untuk memvalidasi data latih pada motif baik yang sulit dibedakan [22].

Penelitian-penelitian terdahulu mayoritas terbatas pada citra kain dan seragam. Walaupun terdapat beberapa penelitian yang menggunakan media *non planar* sebagai objek penelitian seperti deteksi kerusakan pada permukaan logam [4] dan bilah turbin angin [23]. Sementara itu, model deteksi objek seperti YOLO telah mencapai performa canggih untuk objek umum, seperti yang ditunjukkan pada implementasinya untuk mendeteksi korban bencana alam [24] atau untuk mendeteksi cacat pada kain [12]. Akan tetapi, aplikasinya untuk domain spesifik seperti motif etnik yang terukir pada permukaan *non planar* (kayu bertekstur, batu lapuk) masih sangat terbatas.

### 3 Metode Penelitian

Metode penelitian yang digunakan pada penelitian ini disusun menggunakan kerangka kerja riset eksperimental yang berfokus pada pembuatan model berbasis *deep learning*. Proses penelitian akan dilaksanakan secara sekuensial melalui lima tahapan utama, mulai dari perancangan sistem hingga implementasi.

Diagram alir pada Gambar 1 menggambarkan alur penelitian yang akan dilaksanakan:



Gambar 1 Diagram alir penelitian

#### 1. Studi Literatur

Tahapan studi literatur merupakan tahapan yang berfokus pada penguatan teoritis dan pemahaman terkait penelitian sebelum memasuki tahapan selanjutnya. Dalam tahap ini, dilakukan kajian lebih dalam terhadap teori-teori yang berkaitan dengan penelitian, seperti *Convolutional Neural Network* (CNN), khususnya model YOLO. Serta penetapan motif toraja atau Pa'ssura' yang akan digunakan dalam pembuatan model, berdasarkan signifikansi budaya dan variasi visualnya. Model YOLO yang akan digunakan dalam penelitian ini adalah Model YOLO versi 11. Model ini dirilis oleh Ultralytics, memberikan kemampuan akurasi, kecepatan dan efisiensi yang sangat baik. Selanjutnya motif Toraja, ada 7 variasi motif toraja yang akan digunakan pada penelitian ini, yaitu *Pa' Barre Allo*, *Pa' Kapu Baka*, *Pa' Tangke Lumu*, *Pa' Tedong*, *Pa' Ulu Karua*, *Pa' Kadang Pao* dan *Pa' Papan Kandaure*. Ketujuh motif ini yang akan dikumpulkan dan selanjutnya akan dilakukan pembuatan dataset berdasarkan variasi motif yang telah ditentukan.

#### 2. Pengumpulan dan Pembangunan Dataset

Tahap pengumpulan dan Pembangunan dataset merupakan fase inti untuk mengumpulkan kontribusi data fundamental melalui pengambilan data primer langsung dari Tana Toraja, Proses ini melibatkan pengambilan ratusan foto dengan resolusi yang berbagai macam untuk tujuh motif utama pada berbagai media, seperti ukiran kayu di Tongkonan, pahatan batu di kuburan kuno dan kain tenun, dengan memperhatikan variasi kondisi pencahayaan. Setelah citra mentah terkumpul, dilakukan tahapan *Preprocessing* yang meliputi pemilahan, pemotongan dan standarisasi gambar, yang kemudian dilanjutkan dengan proses anotasi atau pelabelan manual menggunakan *bounding box* untuk menandai lokasi setiap motif secara presisi. Selanjutnya untuk meningkatkan ketangguhan model, dilakukan augmentasi data seperti *Flip Horizontal*, *Flip Vertical*, *rotate*, *crop*, *exposure*, *brightness* dan *blur*.

### 3. Pembuatan Model

Tahap pembuatan model, merupakan tahapan untuk melakukan pelatihan dan optimisasi model *deep learning* yang akan digunakan pada tahapan implementasi. Tahapan ini menggunakan hasil dari tahapan sebelumnya yaitu tahapan pengumpulan dan pembuatan dataset. Dataset yang telah melalui *preprocessing* dan *augmentation*, selanjutnya akan digunakan sebagai data latih dan validasi model YOLO. Sebelum dataset digunakan, dataset terlebih dahulu dibagi menjadi 2, yaitu data latih dan data uji dengan proporsi 80% data latih dan 20% data uji. Pelatihan model YOLO dilakukan pada lingkungan local guna menghindari masalah konektivitas yang tidak stabil dan lebih leluasan dalam melakukan *setup environment*. Proses pelatihan disertai dengan evaluasi berkala dan *hyperparameter tuning* untuk menemukan konfigurasi terbaik, seperti penyesuaian *learning rate*, *batch size*, *epoch* ataupun *optimizer*. Luaran dari tahapan ini adalah model AI final yang telah dioptimasi.

### 4. Implementasi Model

Tahap implementasi model, merupakan tahapan untuk mewujudkan model cerdas ke dalam bentuk perangkat lunak yang siap digunakan. Proses ini dimulai dengan mengonversi model final ke format *TensorFlow Lite* (.tflite) agar memiliki performa yang ringan dan efisien pada perangkat *mobile*. Perangkat lunak yang dikembangkan memiliki kemampuan mendeteksi motif melalui kamera secara *real-time* maupun melalui foto atau gambar yang telah diambil sebelumnya.

## 4 Hasil dan Pembahasan

Pada hasil dan pembahasan akan ditampilkan hasil dari masing-masing tahapan yang dilalui dalam proses penelitian diantaranya pengumpulan data, pembangunan dataset, pembuatan model dan implementasi model.

### 4.1. Pengumpulan Data

Pengumpulan data dilakukan dengan cara pengambilan gambar secara langsung pada lokasi penelitian yakni Tana Toraja. Lokasi pengambilan gambar yang akan digunakan sebagai dataset adalah lokasi-lokasi yang menjadi kawasan wisata di Tana Toraja seperti Kete Kesu, Rumah Tongkonan, Kuburan Kuno dan Museum Ne-Gandeng. Lokasi ini menjadi tempat pengambilan dataset primer selain lokasi lain yang memiliki motif toraja. Pengambilan gambar pada lokasi wisata pada Tana Toraja sebagai dataset primer, diharapkan dapat membangun model yang kontekstual, kuat dan *reliable*.

Hasil dari pengambilan data pada lokasi-lokasi tersebut adalah variasi motif yang beragam yaitu *Pa' Barre Allo*, *Pa' Kapu Baka*, *Pa' Tangke Lumu*, *Pa' Tedong*, *Pa' Ulu Karua*, *Pa' Kadang Pao* dan *Pa' Papan Kandaure*.

### 4.2. Anotasi Data

Setelah tahap pengambilan gambar selesai, dilakukan proses pelabelan atau anotasi pada setiap gambar secara manual untuk menentukan *ground truth*. Proses anotasi ini menggunakan platform Roboflow, di mana setiap koordinat motif ditandai secara presisi. Dalam proses anotasi diperlukan seseorang yang dapat membedakan pola atau motif yang digunakan. Gambar yang telah dianotasi kemudian diintegrasikan ke dalam satu kesatuan dataset yang siap untuk diolah lebih lanjut.

### 4.3. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 7 motif berbeda dengan banyak gambar setiap motif adalah 150 gambar. Sehingga total gambar yang digunakan sebagai dataset adalah 1050 gambar. Berikut contoh dataset yang digunakan, dapat dilihat pada Gambar 2 di bawah ini.



**Gambar 2 Dataset motif toraja**

Pada Gambar 2 dapat dilihat, bahwa dataset yang digunakan bersumber dari berbagai media seperti kain yaitu tas ataupun pakaian. Kemudian beberapa motif diambil dari media ukiran kayu yang berada pada rumah tongkonan, atau media batu seperti pada pemakaman kuno.

#### **4.4. Pra Pemrosesan Data**

Ditahap ini akan dilakukan beberapa pemrosesan data pada dataset, sebagai berikut:

##### **1. Seleksi, Pembersihan dan Pembagian Data**

Setelah data diambil, terlebih dahulu dilakukan pemilahan data mana yang memiliki pola atau motif yang telah ditentukan pada studi literatur. Hasil dari tahapan ini, yakni 1048 data gambar yang siap untuk dilakukan pemrosesan selanjutnya. Dua data gambar yang diambil sebelumnya dihapus dari dataset, karena tidak memiliki pola atau motif yang telah ditetapkan.

Selanjutnya data akan dibagi menjadi 3 bagian yaitu data latih, data validasi dan data uji. Persentase pembagian dataset yaitu 80% data latih atau 838 gambar dan 20% uji atau 210 gambar. Pembagian data ini berguna agar model menjadi lebih tahan, mencegah *overfitting* dan mencegah subjektifitas model nantinya.

##### **2. Augmentasi**

Tahap augmentasi digunakan untuk membuat variasi gambar baru dan menambah jumlah gambar pada dataset. Tujuan dari augmentasi agar model yang dibuat dari dataset tersebut menjadi lebih akurat dengan variasi gambar yang lebih bervariasi.

Agar model tidak hanya mengenali objek dalam kondisi ideal, dilakukan berbagai macam tahapan dalam augmentasi data. Tahap augmentasi ditujukan untuk mensimulasikan kondisi dunia nyata yang memiliki berbagai macam kemungkinan, seperti kondisi pencahayaan, kualitas gambar, gambar terpotong dan sebagainya.

Dimulai dengan *Flip Horizontal* dan *Flip Vertical*, tahapan ini akan membalik gambar secara vertikal dan horizontal. Hasil augmentasi ditahap ini bisa dilihat pada Gambar 3.



**Gambar 3 Flip gambar**

Selanjutnya, *Rotate Clockwise*, *Rotate Counter-Clockwise* dan *Rotate Upside-Down*. Ditahap ini akan memutar gambar searah jarum jam, berlawanan arah jarum jam dan memutar terbalik. Hasil dari tahap ini dapat dilihat pada Gambar 4.



**Gambar 4 Rotate gambar**

Dilanjutkan tahap *Crop*, yaitu melakukan pemotongan gambar yang telah diperbesar sebanyak 25% dari ukuran aslinya. Hasil akhir dari tahapan ini bisa dilihat pada Gambar 5.



**Gambar 5 Zoom gambar**

Dan berikutnya dilakukan rotasi pada gambar, sebesar  $15^\circ$  ke kiri dan  $15^\circ$  ke kanan. Hasil dari tahap ini dapat dilihat pada Gambar 6. Tahapan-tahapan yang diterapkan untuk memperkaya perspektif spasial model.



**Gambar 6 Rotation gambar**

Ketangguhan model semakin diperkuat dengan memanipulasi aspek pencahayaan dan kejernihan gambar. Melalui penurunan atau peningkatan intensitas cahaya, sebesar 15% seperti pada Gambar 7.



**Gambar 7 Brightness gambar**

Kemudian, dilakukan perlakuan seperti peningkatan atau penurunan *exposure* atau paparan sebesar 10%, hal ini dapat dilihat pada Gambar 8.



**Gambar 8 Exposure gambar**

Adapun tahap akhir yang dilakukan pada augmentasi adalah *blur*. Hasil penerapan filter *Gaussian Blur* yang diterapkan selama proses augmentasi memberikan tantangan pada model untuk mengenali objek yang tidak fokus, dapat dilihat pada Gambar 9.



**Gambar 9 Blur gambar**

Hasil akhir dari semua tahapan dan perlakuan yang digunakan pada dataset adalah dataset baru dengan variasi yang lebih beragam. Total gambar pada dataset setelah pra pemrosesan yaitu 2520 gambar dengan pembagian data untuk pembuatan model yaitu 2016 gambar untuk data latih dan 504 gambar untuk data uji.

#### **4.5. Pembuatan Model**

Pengembangan model dalam penelitian ini menggunakan arsitektur YOLO11s. Pemilihan varian *small* ini didasarkan pada pertimbangan strategis untuk menyeimbangkan antara akurasi deteksi (*Mean Average Precision*) dan efisiensi komputasi. Melalui konfigurasi ini, sistem mampu melakukan ekstraksi fitur visual yang kompleks dengan latensi rendah, sehingga memungkinkan proses inferensi berjalan secara *real-time* tanpa mengorbankan kedalaman analisis fitur.

Pada fase prapemrosesan, dimensi input citra ditetapkan secara presisi sebesar 640 piksel. Ketetapan ini merupakan standar optimal yang dipilih untuk mempertahankan integritas fitur pada objek berskala kecil, sembari menjaga agar beban kerja memori GPU tetap berada dalam ambang batas aman. Guna menjamin stabilitas sistem pada lingkungan dengan kapasitas RAM terbatas, peneliti menerapkan kebijakan *cache-disabled* yang memaksa data dimuat secara dinamis dari penyimpanan pada setiap iterasi. Langkah preventif ini sangat krusial untuk meminimalisir risiko kegagalan memori (*out of memory*) yang sering menjadi kendala dalam pelatihan model skala besar.


Stabilitas konvergensi dalam pelatihan model dicapai melalui 300 *epoch* dengan dukungan pengoptimal AdamW. Algoritma ini dikombinasikan dengan *learning rate* 0,01, bertujuan untuk mencegah risiko *overfitting* dibandingkan pengoptimal konvensional. Untuk mengakselerasi proses tanpa mereduksi akurasi, teknologi *Automatic Mixed Precision* (AMP) diintegrasikan guna menjalankan komputasi pada presisi FP16. Sebagai instrumen kontrol kualitas, mekanisme *Early Stopping* dengan parameter *patience* 20 diterapkan, yang pada praktiknya berhasil menuntun model mencapai titik konvergensi optimal pada iterasi ke-100.

Sebagai tahap final dalam memperkuat kemampuan generalisasi, model dilengkapi dengan fitur augmentasi otomatis. Penambahan fitur ini menjadi sangat esensial dalam menghadapi kompleksitas visual di lapangan, terutama dalam mengurai fenomena oklusi di mana motif-motif Toraja sering kali

tampil saling bertindih atau terhalang objek lain. Dengan parameter *mask ratio* yang telah disesuaikan, model tetap mampu mengidentifikasi batas-batas spasial objek secara akurat, memastikan sistem tetap *reliabel* meskipun dihadapkan pada tumpukan piksel atau gangguan latar belakang yang dinamis.

#### 4.6. Evaluasi Model

Confusion matrix pada Gambar 10 merepresentasikan kinerja model klasifikasi multikelas terhadap delapan kelas, yaitu *pa\_barre\_allo*, *pa\_kapu\_baka*, *pa\_tangke\_lumu*, *pa\_tedong*, *pa\_ulu\_karua*, *pakadang\_pao*, *pao\_papan\_kandaure*, dan *background*. Sumbu horizontal menunjukkan label aktual (ground truth), sedangkan sumbu vertikal menunjukkan label hasil prediksi model. Nilai pada diagonal utama menggambarkan jumlah prediksi yang benar untuk setiap kelas, sementara nilai di luar diagonal menunjukkan terjadinya kesalahan klasifikasi antar kelas.



Gambar 10 Confusion matrix

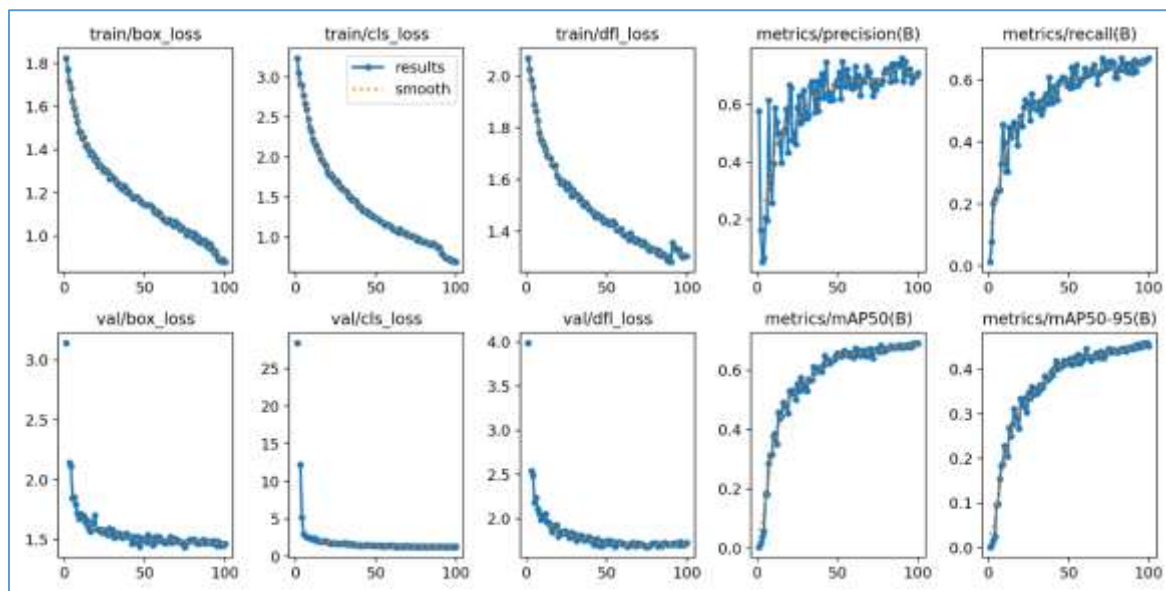
Secara umum, model menunjukkan kemampuan klasifikasi yang relatif cukup baik, yang ditandai dengan dominasi nilai diagonal pada sebagian besar kelas. Kelas *pa\_kapu\_baka* dan *pao\_papan\_kandaure* memiliki jumlah prediksi benar yang relatif tinggi, masing-masing sebesar 69 dan 77 sampel, sehingga dapat dikatakan bahwa karakteristik kedua kelas tersebut lebih mudah dipelajari oleh model. Sebaliknya, kelas *pakadang\_pao* dan *pa\_ulu\_karua* menunjukkan jumlah prediksi benar yang lebih rendah, yaitu masing-masing 24 dan 34 sampel, yang mengindikasikan tingkat kompleksitas fitur atau variasi data yang lebih tinggi.

Meskipun performa klasifikasi secara umum cukup baik, kesalahan klasifikasi yang paling dominan terjadi antara kelas objek dan kelas *background*. Hampir seluruh kelas objek memiliki jumlah kesalahan prediksi yang signifikan ke kelas *background*, seperti pada kelas *Pa' Papan Kandaure* dengan 136 sampel dan *pa\_tangke\_lumu* dengan 51 sampel yang salah diklasifikasikan sebagai latar belakang. Pola ini menunjukkan bahwa model masih mengalami kesulitan dalam membedakan fitur visual objek dengan latar, yang kemungkinan disebabkan oleh kemiripan tekstur, warna, atau konteks visual antara objek dan background. *Pa' Barre Allo*, *Pa' Kapu Baka*, *Pa' Tangke Lumu*, *Pa' Tedong*, *Pa' Ulu Karua*, *Pa' Kadang Pao* dan *Pa' Papan Kandaure*

Selain itu, kelas *background* juga menunjukkan tingkat kesalahan yang cukup tinggi dengan adanya prediksi ke beberapa kelas objek, seperti *pao\_papan\_kandaure* dan *pa\_tangke\_lumu*. Hal ini mengindikasikan adanya kecenderungan model untuk melakukan over-detection, yaitu mengenali objek pada area yang seharusnya merupakan latar belakang. Kondisi ini dapat berdampak pada penurunan presisi model dalam aplikasi nyata.

Secara keseluruhan, hasil analisis confusion matrix ini menunjukkan bahwa meskipun model telah mampu mengenali sebagian besar kelas dengan tingkat akurasi yang memadai, peningkatan kinerja

masih diperlukan, terutama dalam mengurangi kesalahan klasifikasi antara kelas objek dan *background*.



Gambar 11 Hasil *training model*

Pada Gambar 11, proses pelatihan model YOLO11s yang dilaksanakan selama 100 epoch menunjukkan performa yang stabil menuju titik konvergensi optimal tanpa adanya indikasi *overfitting* yang signifikan. Berdasarkan evaluasi metrik kerugian (*loss functions*), terlihat penurunan nilai secara konsisten yang mencerminkan kesehatan proses pembelajaran. Secara spesifik, box loss mengalami reduksi dari nilai awal 1.82 menjadi 0.87 pada *epoch* terakhir, yang mengindikasikan peningkatan presisi model dalam menentukan koordinat spasial atau lokalisasi setiap motif *Pa'ssura* secara akurat. Sejalan dengan itu, class loss pada data validasi juga menunjukkan stabilitas pada angka 1.28, membuktikan kemampuan model dalam membedakan karakteristik visual unik dari ketujuh motif Toraja dengan tingkat kesalahan klasifikasi yang minimal. Kehadiran *Distribution Focal Loss* (DFL) yang melandai secara mulus turut berperan krusial dalam menghaluskan batas deteksi, terutama pada media dengan tekstur kompleks seperti ukiran kayu yang dimensional maupun pahatan batu yang berlumut.

Keberhasilan model dalam mengenali objek lebih lanjut dibuktikan melalui pencapaian metrik standar deteksi objek pada akhir iterasi. Model berhasil mencapai tingkat Presisi sebesar 0.7109 dan Recall sebesar 0.6708, yang menunjukkan keseimbangan optimal antara kemampuan menghindari deteksi palsu (*false positive*) dan ketelitian menemukan seluruh objek dalam citra (*true positive*). Evaluasi menyeluruh melalui *Mean Average Precision* menunjukkan skor mAP50 sebesar 0.6910 dan mAP50-95 sebesar 0.4524. Mengingat tantangan teknis berupa media *non planar* dan lingkungan pengambilan data yang dinamis di lapangan, pencapaian nilai mAP ini mengonfirmasi bahwa model memiliki keandalan yang tinggi untuk diimplementasikan sebagai sistem deteksi *real-time* yang responsif.

## 5 Kesimpulan

Penelitian ini berhasil mengembangkan sistem deteksi dan klasifikasi *real-time* untuk tujuh motif khas Toraja (*Pa'ssura*) menggunakan arsitektur YOLO11s sebagai upaya pelestarian warisan budaya digital. Pembangunan dataset primer yang mencakup berbagai media *non planar* seperti kayu, batu, maupun media seperti kain terbukti krusial dalam memberikan representasi visual yang akurat bagi model. Penerapan teknik augmentasi data, termasuk penggunaan filter *blur* dan manipulasi geometris, mampu meningkatkan jumlah citra secara signifikan dari 1.050 menjadi 2.520, yang secara langsung memperkuat ketangguhan model dalam menghadapi variasi kondisi di lapangan. Berdasarkan analisis hasil pelatihan selama 100 epoch, model menunjukkan konvergensi yang sangat stabil dengan

penurunan *box loss* yang signifikan dari 1,82 menjadi 0,87. Keberhasilan teknis ini dibuktikan dengan pencapaian metrik akhir berupa Presisi sebesar 0,7109 dan Recall sebesar 0,6708, serta nilai mAP50 yang mencapai 0,6910. Meskipun terdapat tantangan teknis dalam membedakan fitur objek terhadap latar belakang (*background*) yang kompleks pada beberapa motif, riset ini telah memberikan bukti fungsional bahwa teknologi *deep learning* dapat diimplementasikan secara akurat. Secara keseluruhan, integrasi model ke dalam format yang efisien untuk perangkat *mobile* mendukung terciptanya ekosistem warisan budaya digital yang lebih cerdas, interaktif, dan berkelanjutan bagi generasi muda. Adapun pengembangan yang dapat dilakukan di masa depan yaitu penggunaan model *instance segmentation* seperti YOLO-Seg. Pendekatan tersebut diharapkan dapat memberikan segmentasi yang lebih presisi untuk mengatasi kendala distorsi visual yang lebih presisi pada media *non planar*. Selain itu, pengembangan model yang lebih ringan untuk optimasi pada perangkat *mobile* dengan spesifikasi terbatas juga menjadi langkah strategis guna meningkatkan pelestarian budaya digital secara luas.

## Ucapan Terima Kasih

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Majelis Pendidikan Tinggi Penelitian dan Pengembangan Pimpinan Pusat Muhammadiyah atas dukungan pendanaan yang diberikan melalui surat Nomor: 2015/I.3/D/2025 pada tahun pendanaan 2026. Dukungan tersebut telah memfasilitasi kelancaran seluruh tahapan riset, mulai dari proses akuisisi data lapangan di Tana Toraja hingga tahap implementasi model *deep learning* Pa'ssura'. Penulis juga menyampaikan apresiasi kepada seluruh pihak yang telah membantu dalam pengumpulan data dan pengembangan sistem demi kelestarian budaya

## Referensi

- [1] S. Salam, M. S. Husain, and Tangsi, "Makna Simbolik Motif-Hias Ukir Toraja," *Panggung*, Vol. 27, No. 3, pp. 284–292, 2017.
- [2] I. Arianti and S. Junaeda, "Pergeseran Nilai dan Makna Budaya Tradisi Rambo Solo' Masyarakat Toraja di Masa Modern," Vol. 3, No. 2, 2021.
- [3] I. Saputra, E. Syarif, and I. Abbas, "*Liang Erong's Symbolic Meaning for the Tana Toraja Community*," *La Geogr.*, Vol. 19, No. 1, pp. 88–102, 2020.
- [4] Z. Jia, Z. Yu, C. Guan, B. Zhao, and X. Wang, "A Co-Designed Framework Combining Dome-Aperture Imaging and Generative AI for Defect Detection on Non-Planar Metal Surfaces," *Sensors*, Vol. 26, No. 3, pp. 1–33, 2026, DOI: 10.3390/s26031044.
- [5] C. Silva and L. Oliveira, "Artificial Intelligence at the Interface between Cultural Heritage and Photography: A Systematic Literature Review," *Heritage*, Vol. 7, No. 7, pp. 3799–3820, 2024, DOI: 10.3390/heritage7070180.
- [6] S. A. Sutresno, "The Classification of Batik Besurek Fabric Motifs in Indonesia Utilizing YOLOv8 for Enhanced Cultural Preservation," *J. Comput. Syst. Informatics*, Vol. 6, No. 1, pp. 86–95, 2024, DOI: 10.47065/josyc.v6i1.6123.
- [7] M. M. A. Wona *et al.*, "Klasifikasi Batik Parang menggunakan Convolutional Neural Network (CNN)," *Pop. J. Penelit. Mhs.*, Vol. 3, No. 1, pp. 62–69, 2023, DOI: 10.58192/populer.v3i1.1666.
- [8] V. Ayumi, I. Nurhaida, and H. Noprison, "Implementation of Convolutional Neural Networks for Batik Image Dataset," *Int. J. Comput. SCI. Appl. Math.*, Vol. 8, No. 1, p. 5, 2022, DOI: 10.12962/j24775401.v8i1.5053.
- [9] E. Sugiarto, F. Budiman, and A. Fahmi, "Implementation of Deep Learning based on Convolution Neural Network for Batik Pattern Recognition," *Kinet. Game Technol. Inf. Syst. Comput. Network, Comput. Electron. Control*, Vol. 4, No. 1, 2025, DOI: 10.22219/kinetik.v10i1.2019.
- [10] A. A. Z. Abidin, Kusri, and F. W. Wibowo, "Implementasi Artificial Neural Network pada Kasus Regresi Linear Berganda untuk memprediksi Jumlah Pakan Ayam Petelur," Vol. 9, pp. 313–323, 2024.
- [11] D. Bagus, B. Wibowo, B. Rahayudi, and L. Muflikhah, "Deteksi Motif Batik menggunakan Pre-Trained Convolutional Neural Network EfficientNet pada Aplikasi Mobile," 2025.

<http://sistemasi.ftik.unisi.ac.id>

- [12] R. R. Hamidi, M. K. Herliansyah, D. Sukma, and E. Atmaja, “Comparative Analysis of YOLOv5n and YOLOv8n Deep Learning Models for Precision Detection of Klowong Defects in Batik Fabric,” Vol. 6, No. 1, pp. 74–86, 2025.
- [13] I. Nurhaida, R. A. M. Zen, V. Ayumi, and H. Wei, “Determining the Number of Batik Motif Object based on Hierarchical Symmetry Detection Approach,” *Indones. J. Electr. Eng. Informatics*, Vol. 9, No. 1, pp. 141–152, 2021, DOI: 10.11591/ijeei.v9i1.2369.
- [14] T. A. P. Sidhi, B. Y. Dwiandiyanta, and F. K. S. Dewi, “Batik Motifs Detection using Pattern Recognition Method,” *J. Buana Inform.*, Vol. 11, No. 1, pp. 55–62, 2020, DOI: 10.24002/jbi.v11i1.3234.
- [15] Y. A. Putri, Y. Azhar, and A. E. Minarno, “Klasifikasi Jenis Batik menggunakan Algoritma Convolutional Neural Network,” *J. Repos.*, Vol. 3, No. 2, pp. 199–206, 2024, DOI: 10.22219/repositor.v3i2.31050.
- [16] M. Misela *et al.*, “Klasifikasi Batik Indonesia menggunakan Convolutional Neural Network (CNN),” 2023.
- [17] S. Arifin and N. Nurfaizah, “Klasifikasi Motif Batik menggunakan Metode Convolutional Neural Network (CNN) dengan Multi Class Clasification,” *J. Ilm. IT CIDA*, Vol. 10, No. 1, p. 30, 2024, DOI: 10.55635/jic.v10i1.206.
- [18] M. Malika and E. Widodo, “Implementasi Deep Learning untuk Klasifikasi Gambar menggunakan Convolutional Neural Network (CNN) pada Batik Sasambo,” *Pattimura Proceeding Conf. SCI. Technol.*, pp. 335–340, 2022, DOI: 10.30598/pattimurasci.2021.knmxx.335-340.
- [19] S. S. F. Ardyani and C. A. Sari, “A Web-based for Demak Batik Classification using VGG16 Convolutional Neural Network,” *Adv. Sustain. SCI. Eng. Technol.*, Vol. 6, No. 4, pp. 0240406-01-0240406–09, 2024, DOI: 10.26877/asset.v6i4.771.
- [20] H. Sastypratiwi, H. Muhardi, and Yulianti, “Batik Recognition and Classification using Transfer Learning and MobileNet Approach,” *Int. J. Informatics Vis.*, Vol. 8, No. 4, pp. 2400–2410, 2024, DOI: 10.62527/joiv.8.4.2407.
- [21] Y. Azhar, M. C. Mustaqim, and A. E. Minarno, “Ensemble Convolutional Neural Network for Robust Batik Classification,” *IOP Conf. Ser. Mater. SCI. Eng.*, Vol. 1077, No. 1, p. 012053, 2021, DOI: 10.1088/1757-899x/1077/1/012053.
- [22] Z. Widyantoko, T. P. Widowati, Isnaini, and P. Trapsiladi, “Expert Role in Image Classification using CNN for Hard to Identify Object: Distinguishing Batik and Its Imitation,” *IAES Int. J. Artif. Intell.*, Vol. 10, No. 1, pp. 93–100, 2021, DOI: 10.11591/ijai.v10.i1.pp93-100.
- [23] L. Shi *et al.*, “DMR-YOLO: An Improved Wind Turbine Blade Surface Damage Detection Method based on YOLOv8,” *Appl. SCI.*, Vol. 16, No. 3, pp. 1–19, 2026, DOI: 10.3390/app16031333.
- [24] M. Sarosa and N. Muna, “Implementasi Algoritma You Only Look Once ( Yolo ) untuk Deteksi Korban Bencana Alam,” *J. Teknol. Inf. dan Ilmu Komput.*, Vol. 8, No. 4, pp. 787–792, 2021, DOI: 10.25126/jtiik.202184407.