

Analisis Unjuk Kerja Klasifikasi Citra Motif Kain Bali Menggunakan Model *Inception* Dan *EfficientNet*

**Ni Putu Widya Yuniari^{1*}, I Made Surya Kumara², I Kadek Agus Wahyu Raharja³,
Gde Wikan Pradnya Dana⁴, I Gede Wira Darma⁵, I Made Adi Bhaskara⁶**

Teknik Komputer, Universitas Warmadewa, Denpasar, Indonesia
*email *Corresponding Author*: putu.widyayuniari@warmadewa.ac.id

Abstract

Bali, with its rich culture and diverse symbolism reflected in the traditional fabric motifs. However, the manual recognition of Balinese fabric motifs faces challenges such as pattern complexity, similarity between motifs, and limited public knowledge. This study aims to address these challenges by using Artificial Intelligence (AI) to automate the process of accurately and efficiently identifying Bali fabric motifs. The research develops a motif recognition model for Bali fabrics using Inception V3 and EfficientNet B1 algorithms in image classification analysis. The research methodology used is experimental, starting with dataset collection, data augmentation, feature extraction, modeling, and testing. The results show that the EfficientNet model achieved an accuracy of 99% on the 25th iteration, much higher than Inception V3, which only achieved 62% accuracy. These results indicate that the EfficientNet model is more effective in recognizing and classifying Bali fabric motifs and strengthen the potential of artificial intelligence in cultural preservation.

Keywords: Bali; Classification; EfficientNet; Inception; Pattern

Abstrak

Bali, dengan kekayaan budaya yang kompleks serta beragam simbolisme. Salah satunya tercermin dalam rupa motif kain tradisional Bali. Namun, pengenalan manual motif kain Bali sering terhambat oleh tantangan seperti kerumitan pola, kesamaan antara motif, dan keterbatasan pengetahuan masyarakat. Penelitian ini bertujuan untuk mengatasi tantangan tersebut dengan menggunakan kecerdasan buatan (AI) untuk mengotomatisasi proses identifikasi motif kain Bali secara akurat dan efisien. Penelitian ini mengembangkan model pengenalan motif kain Bali dengan menggunakan algoritma *Inception V3* dan *EfficientNet B1* dalam analisis klasifikasi citra. Metode penelitian yang digunakan adalah eksperimen, dimulai dengan pengumpulan dataset, augmentasi data, ekstraksi fitur, pemodelan, dan pengujian. Hasil penelitian menunjukkan bahwa model *EfficientNet B1* mencapai akurasi 99% pada iterasi ke-25, jauh lebih tinggi dibandingkan dengan *Inception V3* yang hanya memperoleh akurasi 62%. Hasil ini menunjukkan bahwa model *EfficientNet* lebih efektif dalam mengenali dan mengklasifikasikan motif kain Bali serta memperkuat potensi kecerdasan buatan dalam pelestarian budaya.

Kata kunci: Bali; EfficientNet; Inception; Klasifikasi; Motif

1. Pendahuluan

Bali merupakan salah satu provinsi dengan kekayaan budaya paling banyak dan paling kompleks di Indonesia. Jejak peradaban masa lalu, adat-istiadat leluhur yang masih dipertahankan serta keterpisahan-nya dari peradaban Jawa, membuat Bali memiliki identitas yang unik yang membedakannya dari peradaban lain di Indonesia. Kekayaan ini salah-satunya termanifestasikan dalam Indeks Pembangunan Kebudayaan (IPK) yang mencatat nilai tertinggi jika dibandingkan dengan seluruh Provinsi Di Indonesia. Pada tahun 2023, Indeks Pembangunan Kebudayaan Bali mencatat angka 71,36 point yang meningkat dari tahun sebelumnya sebesar 66,04 point. Nilai ini bahkan lebih tinggi dari rata-rata nasional yang mencatatkan indeks sebesar 57,13 point dan juga lebih tinggi dari Daerah Istimewa Yogyakarta yang masih kental dengan adat dan budaya feodalisme Jawa dengan indeks sebesar 67,90[1]. Angka ini secara simultan,

mengkonfirmasi secara empiris kekayaan kebudayaan pada Provinsi Bali sekaligus membuka kemungkinan akan adanya objek kebudayaan lain yang mungkin belum terindeks dan terdokumentasikan secara utuh.

Salah satu komponen penting dalam Indeks Pembangunan Kebudayaan (IPK) adalah ekspresi budaya dalam keseharian masyarakat. Ekspresi budaya ini kemudian termanifestasikan dalam berbagai bentuk ritus adat dan keseharian masyarakat di Bali. Salah satunya terjewantahkan dalam bentuk desain motif kain tradisional Bali yang sering digunakan oleh masyarakatnya. Bali sendiri terkenal dengan berbagai macam motif kain yang menggambarkan keyakinan, keadaan *socio-cultural* serta status masyarakat Bali[2]. Kain dalam antropologi masyarakat Bali tidak hanya digunakan sebagai pakaian harian atau aksesoris saja, melainkan terdapat nilai-nilai luhur yang melekat dalam peradaban masyarakatnya[3]. Beberapa motif kain Bali menggambarkan sebuah ungkapan, penegasan atas sebuah posisi dalam masyarakat atau pernyataan tertentu[4]. Bahkan beberapa motif bahkan menggambarkan maskulinitas dan status sosial tertentu dan dilarang untuk digunakan oleh sembarang orang[5]. Hal ini menggambarkan kemelekatan yang unik antara sebuah motif dalam kain tradisional Bali sebagai entitas sebuah peradaban[6].

Kajian akan kemelekatan antara motif dan agenda socio kultural telah menemukan sebuah masa dimana keindahan dapat diukur dan citra dapat diidentifikasi serta diterjemahkan secara komputasi. Atau dalam kajian yang lebih kontemporer dapat dikatakan bahwa saat ini objek pemajuan kebudayaan berupa motif kain tradisional sudah dapat diidentifikasi secara empiris. Hal ini membuka peluang baru dalam pendokumentasian budaya yang tidak terbatas pada objek naratif berbasis antropologi saja, melainkan sebagai sebuah objek yang mengandung nilai estetika dimana dalam setiap bit-bit datanya dapat diukur dalam kajian *Ethnomathematics*[7]. Teknik ini kemudian dikenal dengan analisis citra motif (*pattern recognition*)[8].

Salah-satu metode yang dapat digunakan dalam kajian *pattern recognition* adalah studi komputasi (*computational study*). Dalam kajian yang lebih mutakhir bahkan sudah melibatkan kecerdasan buatan (AI) didalamnya[9]. Studi komputasi melibatkan serangkaian baris-baris code untuk menerjemahkan sebuah citra menjadi bit-bit data[10]. Sementara kecerdasan buatan (AI) dalam *pattern recognition* membantu untuk mempercepat prosesnya serta menerjemahkan hasilnya kedalam sebuah *insight* yang lebih mudah diterima sehingga menghasilkan *AI based pattern recognition*[11]. Bentuknya dapat berupa klasifikasi citra[12], identifikasi citra[13], atau bahkan Generative AI[14].

Studi analisis citra dalam motif kain tradisional dengan memanfaatkan teknologi kecerdasan buatan bukan merupakan studi yang baru. Namun pemanfaatannya dalam pemajuan kebudayaan di Indonesia masih sangat minim. Diantara beberapa penelitian sebelumnya (*recent study*) terkait kasus ini adalah penelitian dari Shafira & Fauzy pada tahun 2021 yang menggunakan algoritma *Convolutional Neural Network* (CNN) untuk menganalisis dan mengklasifikasikan citra pada kain tenun Nusantara. Penelitian ini menggunakan 100 iterasi dan menghasilkan loss sebesar 1,3385 dan akurasi sebesar 73% dengan menggunakan optimizer Adam[15].

Peningkatan kualitas kemudian dilakukan oleh Athala dkk pada tahun 2021 yang menganalisis motif pada beberapa kain tradisional di Indonesia dengan menggunakan modul-modul pengembangan dari CNN, antara lain: *Resnet50 V2*, *VGG16*, *VGG19*, *MobileNetV2*, dan *Inception V3*. Modul *ResNet* mendapatkan akurasi sebesar 79,2%; *VGG16* mendapatkan akurasi sebesar 79,2%; *VGG19* mendapatkan akurasi sebesar 79,9%; *MobileNetV2* mendapatkan akurasi sebesar 83,4%; dan *Inception V3* mendapatkan akurasi terbaik sebesar 83,7%. Dari penelitian ini didapatkan insight bahwa *Inception V3* bekerja lebih baik dari model-model lainnya[10].

Penelitian berikutnya dilakukan oleh Shakya dkk pada tahun 2021. Penelitian ini mencoba membandingkan algoritma *ResNet* dengan *MobileNet* untuk melakukan klasifikasi pada identifikasi motif. Penelitian ini menghasilkan akurasi 80,77% pada *ResNet* dan 95% pada *MobileNet*[16].

Untuk studi kasus motif kain endek Bali, salah satu penelitian terbaru dilakukan oleh Hendrawati dkk pada tahun 2023. Penelitian ini dilakukan dengan menggunakan modul *ResNet50* yang masih merupakan bagian dari keluarga *Convolutional Neural Network* (CNN). Penelitian ini berhasil mendapatkan akurasi sebesar 90,69%; *recall* sebesar 90,69%; *precision* sebesar 90,6%; dan *f1-score* sebesar 90,6%. Nilai ini cukup besar jika dibandingkan dengan performa pada penelitian sebelumnya. Berdasarkan hasil analisis, tingginya performa diakibatkan

oleh penggunaan metode augmentasi yang memungkinkan model belajar lebih banyak pada pola yang berbeda dengan motif yang sama. Hal ini memungkinkan model untuk mempelajari motif-motif terkait walau dalam posisi yang berbeda sehingga menghasilkan model yang memiliki performa sangat baik[17].

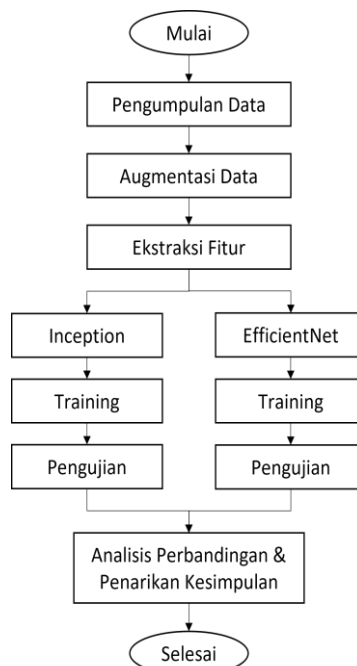
Dari berbagai studi diatas baik secara teknis maupun secara teoritis terkait dengan analisis motif kain tradisional khususnya yang dilakukan dengan menggunakan kecerdasan buatan (AI), telah menunjukkan kemajuan yang signifikan dalam pengklasifikasian dan identifikasi motif. Namun hal ini masih terdapat beberapa kesenjangan penting yang perlu diperhatikan. Sebagian besar penelitian terdahulu tersebut belum fokus pada motif kain Bali secara khusus dan cenderung mengkaji motif-motif kain tradisional Indonesia secara umum. Terdapat penelitian yang mulai mengarah pada motif kain Endek Bali, namun penelitian yang lebih spesifik mengenai varian motif Bali lainnya dan hubungan budaya yang terkandung dalam setiap desain masih sangat terbatas. Selain itu, meskipun teknik augmentasi telah digunakan untuk meningkatkan akurasi model, kebanyakan penelitian terdahulu hanya fokus pada augmentasi berbasis posisi visual motif. Tidak banyak yang mengeksplorasi variasi motif berdasarkan konteks budaya, seperti bagaimana motif tertentu digunakan dalam adat atau untuk menggambarkan status sosial, yang jelas memiliki dampak terhadap pemahaman dan interpretasi motif itu sendiri.

Pada penelitian ini berfokus pada penerapan kecerdasan buatan yang tidak hanya mengenali pola secara visual, tetapi juga memberikan pemahaman yang lebih mendalam tentang nilai budaya dan estetika yang terkandung dalam motif tersebut. Salah satu kebaruan penelitian ini adalah penggunaan AI untuk memetakan dan mengklasifikasikan motif berdasarkan konteks budaya, sosial, dan geografis, Hal ini memungkinkan pemahaman yang lebih luas tentang keberagaman budaya Bali. Pada penelitian ini juga mengembangkan teknik augmentasi yang lebih kontekstual, dengan memperkenalkan variasi motif yang dipengaruhi oleh latar belakang adat dan sosial. Selain itu, pemanfaatan model AI seperti *multi-modal AI* yang menggabungkan data visual dan naratif juga mulai diterapkan untuk memberikan insight yang lebih holistik, memadukan analisis citra dengan pemahaman tentang makna sosial dan ritual di balik setiap motif.

3. Metodologi

1) Alur Penelitian

Adapun alur dari penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

Penelitian dimulai dari pengumpulan data, kemudian dilanjutkan dengan tahap augmentasi data untuk merekayasa data. Kemudian dilanjutkan dengan ekstraksi fitur dengan teknik *image to vector* yang bertujuan untuk mengubah data gambar menjadi bentuk *vector numeric*. Kemudian dilanjutkan dengan proses pembuatan model. Model yang digunakan dalam penelitian ini adalah model *InceptionV3 & EfficientNetB1*. Kemudian dilanjutkan dengan proses pelatihan menggunakan 25 iterasi dan diakhiri dengan proses pengujian, analisis perbandingan dan penarikan kesimpulan. Bahasa pemrograman yang digunakan pada penelitian ini seluruhnya menggunakan *Python* dengan *library* dari *tensorflow*. Adapun *notebook* yang digunakan untuk melakukan pemrograman adalah *Google Colab*.

2) Teknik Pengumpulan Data

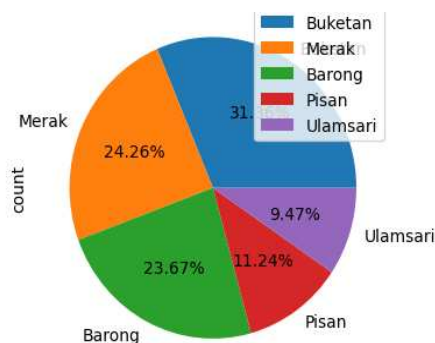
Dataset yang digunakan pada penelitian ini adalah 77 citra pada data train dan 26 citra pada data test diambil menggunakan metode *scraping* dari berbagai sumber di internet yaitu *google image* dan situs <https://www.kaggle.com/dionisiusdh/indonesian-batik-motifs> dengan mengunduh (*download*) gambar terkait dengan objek dalam penelitian ini.

Dataset ini terdiri dari 5 kelas motif, antara lain: motif pisan, motif buketan, motif barang, motif merak, dan motif ulamsari. Komposisi data untuk setiap kelas motif adalah sebagai berikut: untuk motif pisan terdapat 16 citra dalam data pelatihan dan 6 citra dalam data pengujian, untuk motif buketan terdapat 15 citra dalam data pelatihan dan 5 citra dalam data pengujian, untuk motif barang terdapat 14 citra dalam data pelatihan dan 5 citra dalam data pengujian, untuk motif merak terdapat 15 citra dalam data pelatihan dan 5 citra dalam data pengujian, dan untuk motif ulamsari terdapat 17 citra dalam data pelatihan dan 5 citra dalam data pengujian. Dengan komposisi tersebut, total jumlah citra untuk data pelatihan adalah 77 citra, sementara total untuk data pengujian adalah 26 citra. Beberapa sampel datasetnya dapat dilihat pada Gambar 2.



Gambar 2. Dataset Motif (a) Pisan, (b) Buketan, (c) Barong, (d) Merak, dan (e) Ulamsari

Distribusi persentase jumlah data dari masing-masing kelas motif pada Gambar 2 dapat dilihat pada Gambar 3.



Gambar 3. Sebaran Jumlah Data Pada Tiap Kelas (Motif)

Dari Gambar 3 dapat disimpulkan bahwa sebaran jumlah data sangat tidak merata. Dimana 31% data yang dimiliki adalah data motif Buketan, sementara hanya 9,47% yang merupakan motif ulamsari. Untuk menghindari terjadinya *skewness*, maka akan dilakukan *oversampling* dengan menggunakan *SMOTE*.

3) Augmentasi Data

Augmentasi data adalah sebuah Teknik untuk merekayasa gambar sekaligus memperbanyaknya. Adapun Teknik rekayasa gambar yang digunakan dalam augmentasi pada penelitian ini antara lain: *flip*, *rotate*, *noising*, dan *contrast adjustment*.

Salah satu contoh gambar yang akan dilakukan augmentasi dapat dilihat pada Gambar 4.



Gambar 4. Contoh *Original Image* Sebelum Augmentasi

Augmentasi pertama akan dilakukan dengan melakukan pembalikan (*flip*) pada gambar. Pembalikan dilakukan baik secara vertikal maupun secara horizontal. Hasilnya dapat dilihat pada Gambar 5.



(a) (b)

Gambar 5. (a) *Horizontal Flip*, (b) *Vertical Flip*.


Kemudian augmentasi dilanjutkan dengan melakukan rotasi gambar. Pada penelitian ini, rotasi akan dilakukan pada sudut 90° dan -90° . Hasilnya dapat dilihat pada Gambar 6.



(a) (b)


Gambar 6. (a) 90° *Rotation*, (b) -90° *Rotation*.

Kemudian augmentasi dilanjutkan dengan melakukan *noising*. Teknik *noising* yang digunakan adalah *Gaussian Noise* dan *Laplace Noise*. Hasilnya dapat dilihat pada Gambar 7.



Gambar 7. (a) *Gaussian Noise*,(b) *Laplace Noise*.

Kemudian augmentasi dilanjutkan dengan merekayasa kontras. Teknik yang digunakan antara lain: *Gamma Contrast*, *Sigmoid Contrast*, dan *Linear Contrast*. Hasilnya dapat dilihat pada Gambar 8.




Gambar 8. (a) *Gamma Contrast*, (b) *Sigmoid Contrast*, (c) *Linear Contrast*

Augmentasi data membuat mesin dapat mempelajari lebih banyak motif dengan tampilan atau penempatan yang berbeda-beda. Sehingga diharapkan mesin akan lebih andal dalam memprediksi data dalam posisi apapun.

4) Teknik Ekstraksi Fitur

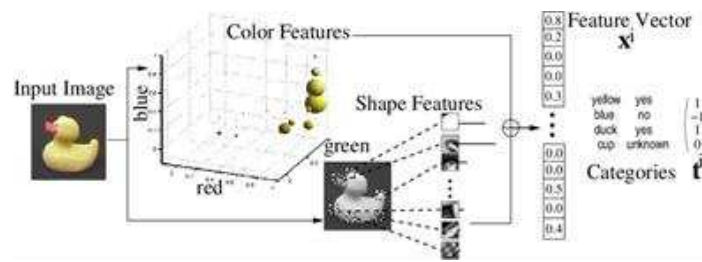
Ekstraksi fitur adalah proses mengubah data dalam bentuk apapun (dalam hal ini berupa citra gambar) menjadi bentuk vektor numerik yang dapat dibaca oleh program[18]. Dalam terminologi pengolahan citra, proses ini sering disebut dengan *image processing*. Metode ekstraksi fitur yang digunakan adalah *image to vector*. Pada proses ini gambar akan diekstraksi langsung menjadi vektor menggunakan indeks warna.

Tahap pertama, ukuran gambar akan disesuaikan menjadi $150\text{pixel} \times 150\text{pixel}$ untuk menyamakan node-node pengambilan indeks warna. Kemudian pada setiap *pixel* akan dilakukan proses *color extraction* menggunakan *RGB-Extraction*. Skema proses *RGB-Extraction* dapat dilihat pada Gambar 9.



Gambar 9. Color Extraction.

Proses pada Gambar 9 dilakukan pada semua node *pixel* data, sehingga menghasilkan sebuah vektor dengan dimensi $150 \times 150 \times 3$ [19]. Keseluruhan proses ekstraksi fitur dapat dilihat pada Gambar 10.



Gambar 10. *Image to Vector*.


Proses ini kemudian dilakukan pada keseluruhan dataset untuk menghasilkan *vektor training*.

5) Arsitektur Inception

Inception adalah sebuah model jaringan syaraf tiruan (ANN) yang dikembangkan untuk mengatasi masalah dalam *image recognition* dan *object detection*. *Inception* dirancang untuk membuat model lebih efisien, cepat, dan akurat dengan cara mengurangi jumlah parameter dan komputasi[20].

Model *Inception* yang digunakan pada penelitian ini adalah Model *Inception V3*. Model ini memperkenalkan beberapa perbaikan pada stabilitas pelatihan (*training*) dan efisiensi, termasuk normalisasi batch (*batch normalization*) serta konvolusi terpisah. Hal ini memungkinkan proses pelatihan berjalan lebih optimal dan reliable, namun membutuhkan proses yang lebih panjang untuk meningkatkan performa pada setiap proses pelatihannya.

Model *InceptionV3* kemudian direkayasa dengan proses *fine tuning* dengan menambahkan layer *Global Average Pooling* dan *Dropout layer* untuk meningkatkan efisiensi pada proses pelatihan dan menghapus node-node yang memiliki kontribusi rendah. Arsitektur lengkap Model *InceptionV3* yang digunakan dapat dilihat pada Gambar 11.




Gambar 11. Arsitektur InceptionV3.

6) Arsitektur EfficientNet

EfficientNet adalah sebuah model deep learning dengan pendekatan *compound scaling* yang biasa digunakan untuk melakukan kerja-kerja pengolahan citra[21]. *EfficientNet* dibuat oleh Google pada tahun 2019 dan terkenal dengan efisiensi tinggi dan akurasi yang sangat baik. *EfficientNet* sendiri masih merupakan keluarga *Convolutional Neural Network* yang mengidentifikasi data menggunakan *matrix-matrix* konvolusi[22]. *Matrix* ini mengolah dan mencari tau bagian terpenting data dalam sebuah proses yang disebut *Pooling*.

Penelitian ini dilakukan dengan menggunakan arsitektur *EfficientNetB1* yang sudah direkayasa dengan proses *fine tuning* dengan menambahkan layer *Global Average Pooling* dan *Dropout layer* untuk menghapus node-node yang memiliki kontribusi rendah. Penambahan layer ini diharapkan mampu meningkatkan performansi dan meningkatkan efisiensi pada proses pelatihan. Arsitektur lengkap *EfficientNetB1* yang digunakan dapat dilihat pada Gambar 12.

Gambar 12. Arsitektur *EfficientNet*.

7) Proses Pelatihan

Setelah vektor gambar terbentuk melalui proses ekstraksi fitur, dan arsitektur model sudah dibuat, tahapan berikutnya adalah melakukan proses training dari vektor gambar kedalam model yang sudah dibuat. Proses pelatihan dimulai dengan membagi data menjadi data *training* dan data *testing* dengan perbandingan sekitar 75% dataset digunakan untuk pelatihan (*training*) dan 25% digunakan untuk pengujian (*testing*). Data *training* akan digunakan untuk melakukan proses pelatihan sedangkan data *testing* akan digunakan sebagai data validasi dan pengujian. Proses iterasi akan dilakukan sebanyak 25 kali pada masing-masing model.

8) Teknik Analisis Data

Analisis data akan dimulai dengan melakukan pengujian pada keseluruhan data *testing*. Kemudian akan dibandingkan hasil prediksi model dengan label yang sebenarnya. *Metric* pengukuran pertama yang digunakan adalah *confusion matrix*. *Confusion matrix* adalah matriks pengukuran yang membandingkan antara data hasil prediksi dengan data yang sebenarnya pada setiap kelas[23]. Contoh dari *confusion matrix* dapat dilihat pada Gambar 13.

		Classifier Prediction	
		Positive	Negative
Actual Value	Positive	True Positive	False Negative
	Negative	False Positive	True Negative

Gambar 13. *Confusion Matrix*

Metrik selanjutnya yang digunakan dalam penelitian ini adalah akurasi. Akurasi menyatakan seberapa akurat model memprediksi data apakah positif, negatif, atau netral. Untuk menghitung nilai akurasi dari *confusion matrix* dapat menggunakan persamaan (1).

$$cc = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

Metrik selanjutnya yang digunakan dalam penelitian ini adalah *precision*. *Precision* membandingkan jumlah data positif yang berhasil diprediksi dibagi dengan jumlah data yang tergolong positif. Untuk menghitung *precision* dari *confusion matrix* dapat menggunakan persamaan (2).

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

Metrik berikutnya yang digunakan dalam penelitian ini adalah *recall*. *Recall* merupakan perbandingan antara jumlah data positif yang berhasil diprediksi dibagi dengan jumlah data yang benar-benar positif. Penarikan kembali menyatakan seberapa baik model memprediksi data positif. Untuk menghitung *recall* dari *confusion matrix* dapat menggunakan persamaan (3).

$$Recall = \frac{TP}{TP + FN} \tag{3}$$


Metrik terakhir yang digunakan dalam penelitian ini adalah *F1-Score*. *F1-Score* adalah rata-rata harmonis antara *precision* dan *recall*. *F1-Score* dapat dihitung menggunakan persamaan (4).

$$F1 = \frac{Precision * Recall}{Precision + Recall} \tag{4}$$

4. Hasil dan Pembahasan


4.1 Model Inception V3

Setelah melakukan proses *training* pada 25 iterasi, didapatkan trend akurasi menunjukkan peningkatan dan trend *loss* mengalami penurunan. Hal ini mengindikasikan bahwa proses pembelajaran pada Model *Inception* berlangsung dengan baik. Grafik unjuk kerja akurasi selama proses *training* pada Model *Inception* dapat dilihat pada Gambar 14.



Gambar 14. Trend Akurasi Pelatihan Model *Inception V3*.


Sementara grafik unjuk kerja *loss* selama proses *training* pada Model *Inception* dapat dilihat pada Gambar 15.



Gambar 15. Trend Loss Pelatihan Model *Inception V3*.

Dari Gambar 14 dan Gambar 15 tidak ditemukan indikasi *overfitting*, sehingga model dapat dikatakan valid dan dapat digunakan.

Setelah melalui proses *training*, kemudian dilakukan proses pengujian pada model *InceptionV3* yang sudah dilatih. Proses ini dilakukan dengan menggunakan data *testing* yang sudah disiapkan. *Confusion matrix* dari hasil pengujian Model *InceptionV3* dapat dilihat pada Gambar 16.



Gambar 16. *Confusion Matrix Model Inception V3.*

Dari Gambar 16 didapatkan bahwa sebagian besar data berhasil diprediksi, hanya saja masih terdapat beberapa *error* atau kesalahan prediksi yang menghasilkan unjuk kerja yang kurang memuaskan.

Dari *confusion matrix* pada Gambar 16, kemudian dapat dihitung nilai akurasi, *precision* dan *recall* pada masing-masing label. Hasilnya dapat dilihat pada Tabel 1.


Tabel 1. Hasil Pengujian Model *InceptionV3.*

Label	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
0 (Pisan)	73%	59%	65%
1 (Buketan)	52%	48%	50%
2 (Merak)	87%	40%	55%
3 (Ulamsari)	53%	84%	65%
4 (Barong)	65%	81%	72%
Akurasi	62%		

Dari Tabel 1 dapat disimpulkan bahwa akurasi Model *InceptionV3* yang didapatkan adalah 62%.


4.2 Model *Efficient Net*

Setelah melakukan proses training pada 25 iterasi, didapatkan trend akurasi menunjukkan peningkatan dan trend *loss* mengalami penurunan. Hal ini mengindikasikan bahwa proses pembelajaran berlangsung dengan baik. Grafik unjuk kerja akurasi selama proses *training* pada Model *EfficientNet* dapat dilihat pada Gambar 17.



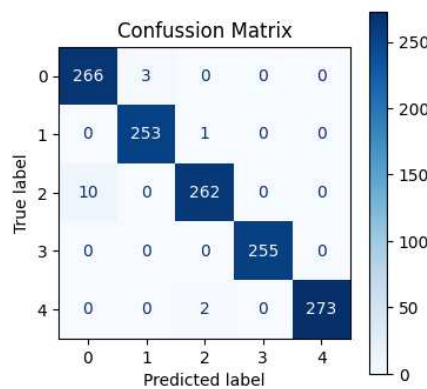
Gambar 17. Trend Akurasi Pelatihan Model *Efficient Net.*

Sementara grafik unjuk kerja *loss* selama proses training pada model *EfficientNet* dapat dilihat pada Gambar 18. Dari kedua grafik diatas tidak ditemukan indikasi *overfitting*, sehingga model dapat dikatakan valid dan dapat digunakan.



Gambar 18. Trend Loss Pelatihan Model *EfficientNet*

Setelah melalui proses training, kemudian dilakukan proses pengujian pada model *EfficientNet* yang sudah dilatih. Proses ini dilakukan dengan menggunakan data testing yang sudah disiapkan. *Confusion matrix* dari hasil pengujian model *EfficientNet* dapat dilihat pada Gambar 19.



Gambar 19. *Confusion Matrix* Model *EfficientNet*.

Dari Gambar 19 dapat ditunjukkan bahwa hasilnya jauh lebih baik daripada *confusion matrix* pada Model *Inception*. Hampir seluruh data dapat diprediksi dengan benar. Hanya saja, masih terdapat kesalahan prediksi, diantaranya: 3 data pada label '0' (Pisan), 1 data pada label '1' (Buketan), 10 data pada label '2' (Merak) dan 2 data pada label '4' (Barong).

Dari *confusion matrix* pada Gambar 16, kemudian dapat dihitung nilai akurasi, *precision* dan *recall* pada masing-masing label. Hasilnya dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pengujian Model *EfficientNet*

Label	Precision	Recall	F1-Score
0 (Pisan)	96%	99%	98%
1 (Buketan)	99%	100%	99%
2 (Merak)	99%	96%	98%
3 (Ulamsari)	100%	100%	100%
4 (Barong)	100%	99%	100%
Akurasi	99%		

Dari Tabel 2 dapat disimpulkan bahwa akurasi Model *EfficientNet* yang didapatkan adalah 99%. Nilai ini menunjukkan unjuk kerja pelatihan yang hampir sempurna dan nilainya jauh lebih tinggi dari model *Inception*.

4.3 Pembahasan

Berdasarkan kedua pemaparan dari hasil pengujian diatas dapat diketahui bahwa Model *EfficientNet* cenderung bekerja lebih baik daripada Model *Inception* jika ditinjau dari *metric* akurasi, *precision*, *recall* dan *f1-score*. Berdasarkan keempat *metric* menunjukkan hasil yang jauh

lebih baik pada model *EfficientNet*. Hal ini sesuai dengan teori dimana *EfficientNet* akan cenderung bekerja dengan lebih baik karena melalui proses *compound scaling* yang sangat efisien dan memiliki unjuk kerja tinggi dalam pengolahan citra.

Pada proses pelatihan juga dapat dilihat dari Gambar 14 dan Gambar 15 (untuk *Inception*) dan Gambar 17 dan Gambar 18 (untuk Model *EfficientNet*) dapat dilihat bahwa peningkatan unjuk kerja pelatihan terjadi lebih cepat pada Model *EfficientNet* daripada *Inception*. Pada model *EfficientNet*, peningkatan unjuk kerja terjadi dengan sangat signifikan pada iterasi ke-3, sementara peningkatan unjuk kerja yang signifikan pada Model *Inception* baru terjadi pada iterasi ke-17. Hal ini sesuai dengan analisis teori dimana Model *Inception* membutuhkan proses yang lebih panjang untuk meningkatkan unjuk kerja pada setiap proses pelatihannya.

Jika dilihat dari *confusion matrix*, hasil pengujian pada Model *EfficientNet* juga jauh lebih baik dimana hanya sangat sedikit kegagalan prediksi yang terjadi jika dibandingkan dengan model *Inception*. Model *Inception* menghasilkan akurasi 62% dan Model *EfficientNet* menghasilkan akurasi 99%.

Hasil pada penelitian ini sejalan dengan penelitian terdahulu, seperti yang dilakukan oleh Shakya dkk pada tahun 2021 yang juga membandingkan berbagai model CNN untuk klasifikasi motif, di mana hasil penelitian menunjukkan bahwa model berbasis *MobileNet* memiliki akurasi yang sangat baik [16]. Meskipun hasilnya berbeda dalam hal model yang digunakan (*MobileNet* dibandingkan dengan *EfficientNet*), temuan ini mengindikasikan bahwa model berbasis CNN yang lebih efisien dalam pemrosesan citra, seperti *MobileNet* dan *EfficientNet*, seringkali lebih unggul dalam hal kecepatan pelatihan dan akurasi, terutama ketika digunakan untuk tugas klasifikasi dengan dataset yang lebih kecil atau dengan keterbatasan sumber daya komputasi.

Perbandingan ini juga menunjukkan kesesuaian dengan temuan Athala dkk pada tahun 2021, yang menggunakan model CNN seperti *ResNet*, *VGG*, dan *Inception* untuk klasifikasi motif kain tradisional Indonesia, dimana *InceptionV3* juga digunakan, namun dengan akurasi yang tidak sebaik model-model lain seperti *MobileNetV2* atau *Inception V3* [10]. Di sisi lain, penelitian ini menambah wawasan baru dengan menguji *EfficientNet*, yang secara teoritis lebih efisien berkat teknik *compound scaling* dan lapisan-lapisan yang lebih sedikit namun dengan performa yang sangat baik pada pengolahan citra. Hal ini memperkuat temuan dalam literatur yang lebih luas tentang bagaimana *EfficientNet* menjadi pilihan yang lebih baik untuk aplikasi pengenalan pola yang melibatkan dataset yang lebih kecil dan penggunaan komputasi yang lebih efisien.

Temuan pada penelitian Hendrawati dkk pada tahun 2023, juga memperkuat penelitian ini yang memanfaatkan model *ResNet50* untuk klasifikasi motif kain Endek Bali dengan akurasi yang sangat tinggi (90,69%) [17]. Temuan tersebut memberikan bukti lebih lanjut tentang potensi besar model berbasis CNN dalam menganalisis citra motif kain tradisional. Namun, penelitian ini menambahkan variasi dalam pendekatan dengan menggunakan *EfficientNetB1* yang lebih efisien dan berhasil memberikan unjuk kerja yang jauh lebih baik, sejalan dengan hasil dari beberapa studi terkait tentang pentingnya memilih model dengan kemampuan komputasi yang efisien.

Perbandingan dengan temuan-temuan tersebut menunjukkan bahwa meskipun model *InceptionV3* telah digunakan secara luas dalam pengklasifikasian motif kain tradisional Indonesia, penelitian ini mengungkap bahwa *EfficientNet* menawarkan hasil yang lebih signifikan. Hasil ini membuka peluang bagi penerapan model-model efisien lainnya untuk analisis motif-motif tradisional, serta memberikan *insight* untuk riset selanjutnya mengenai bagaimana mengoptimalkan model-model ini untuk memperkaya pelestarian budaya dengan pendekatan berbasis kecerdasan buatan.

5. Simpulan

Penelitian ini berhasil membuat sebuah model klasifikasi citra kain Bali yang terdiri dari: motif Pisan, motif Buketan, motif Merak, motif Ulamsari dan motif Barong dengan membandingkan Model *InceptionV3* dan *EfficientNetB1*. Berdasarkan hasil pelatihan dan pengujian yang telah dipaparkan pada bagian hasil dan pembahasan dapat disimpulkan bahwa pada berbagai data, Model *EfficientNet* bekerja lebih baik daripada Model *Inception*. Model *EfficientNet* mendapatkan akurasi sebesar 99%, sedangkan *Inception* hanya mendapatkan akurasi sebesar 62%. Hasil yang sama juga didapatkan pada *metric precision*, *recall* dan *f1-score* pada setiap label. Dari hasil *confusion matrix* juga ditemukan bahwa error lebih banyak terjadi pada Model *Inception* daripada model *EfficientNet*.

Tingginya unjuk kerja pada Model *EfficientNet* sudah sesuai dengan kerangka teori dimana kompleksitas Model *EfficientNet* dengan kerangka kerja *compound scaling* akan memberikan

proses *training* yang lebih panjang sehingga berimplikasi pada tingginya unjuk kerja. Sementara pada Model *Inception*, membutuhkan proses yang lebih panjang untuk meningkatkan unjuk kerja pada setiap proses pelatihannya. Hal ini juga dapat dilihat dari peningkatan unjuk kerja pada setiap iterasi pelatihannya.

Secara keseluruhan, penelitian ini berhasil membuktikan bahwa *EfficientNet* bekerja lebih baik daripada *Inception* dalam kasus klasifikasi citra motif kain Bali. Namun tentunya masih terdapat beberapa kekurangan yang dapat menjadi saran dan masukan untuk penelitian berikutnya antara lain: menggunakan proses normalisasi atau *layer normalization* untuk menyederhanakan proses perhitungan. Teknik ini tentunya akan berimplikasi positif pada waktu yang dibutuhkan untuk melakukan proses training. Kemudian untuk saran berikutnya juga dapat digunakan *callback function early stopping* untuk menghentikan proses *training* jika tidak ditemukan peningkatan unjuk kerja pada iterasi tertentu. Hal ini tentunya menghindari pembelajaran berulang yang tidak perlu yang secara simultan dapat mengurangi beban *resource*.

Harapannya, penelitian ini dapat menjadi acuan bagi penelitian berikutnya dalam topik upaya pendokumentasian objek kebudayaan dalam bentuk programatik menggunakan kecerdasan buatan.

Referensi

- [1] Kemendikbud, "Indeks Pembangunan Kebudayaan | Provinsi Bali." [Daring]. Tersedia pada: <https://ipk.kemdikbud.go.id/provinsi/51>
- [2] A. Parameswara, I. a. N. Saskara, I. M. S. Utama, dan N. P. W. Setyari, "Exploring Cultural Value and its Sustainability of Balinese Handwoven Textiles," *TEXTILE*, vol. 21, no. 1, hlm. 174–197, 2022, doi: 10.1080/14759756.2022.2043517.
- [3] N. S. Budi, N. T. B. Affanti, dan N. S. Mataram, "Ornamental patterns of contemporary Indonesian batik: clothing for strengthening the articulation of appearance characteristics," *Wacana Seni Journal of Arts Discourse*, vol. 23, no. 2, hlm. 16–28, 2024, doi: 10.21315/ws2024.23.2.
- [4] D. Kodžoman, "The psychology of clothing," *Textile & Leather Review*, vol. 2, no. 2, hlm. 90–103, 2019, doi: 10.31881/tlr.2019.22.
- [5] M. R. Mahendra, D. A. R. Putra, dan L. Luerdi, "Eksplorasi Diplomasi Budaya Indonesia Dalam Perhelatan Bali Street Carnival," *Complex: Jurnal Multidisiplin Ilmu Nasional*, vol. 2, hlm. 32–39, 2025.
- [6] A. Christia dkk., *Kecerdasan Buatan: Arah dan Eksplorasinya*. Prasetiya Mulya Publishing, 2024.
- [7] A. Irawan, M. Lestari, W. Rahayu, dan R. Wulan, "Ethnomathematics batik design Bali island," *J Phys Conf Ser*, vol. 1338, no. 1, hlm. 012045, 2019, doi: 10.1088/1742-6596/1338/1/012045.
- [8] I. M. A. Mahawan dan A. Harjoko, "Pattern recognition of Balinese carving motif using Learning Vector Quantization (LVQ)," dalam *Communications in Computer and Information Science*, 2017, hlm. 43–55. doi: 10.1007/978-981-10-7242-0_4.
- [9] C.V. Haritha, "An overview of Pattern Recognition," *International Journal Of Research Publication And Review*, Vol 3, Issue 7, pp 1883-1889, July 2022, doi: <https://doi.org/10.55248/gengpi.2022.3.7.49>
- [10] V. H. Athala, A. H. Rangkuti, N. F. Luthfi, S. V. Aditama, dan J. M. Kerta, "Improved pattern recognition of various traditional clothes with Convolutional neural network," dalam *3rd International Symposium on Material and Electrical Engineering Conference (ISMEE)*, Bandung, Indonesia, 2021, hlm. 15–20. doi: 10.1109/ISMEE54273.2021.9774136.
- [11] G. Lakshmi dan N. Sharada, "Artificial Intelligence based Pattern Recognition," *International Journal of Engineering and Management Research*, vol. 9, no. 2, hlm. 29–32, 2019, doi: 10.31033/ijemr.9.2.4.
- [12] M. Ghazal dan K. Abdullah, "Face recognition based on curvelets, invariant moments features and SVM," *TELKOMNIKA Indonesian Journal of Electrical Engineering*, vol. 18, hlm. 733–739, Apr 2020, doi: 10.12928/Telkomnika.v18i2.14106.
- [13] Z. Feng dan X. Hua, "Pattern recognition and its application in image processing," *J Phys Conf Ser*, vol. 1518, no. 1, hlm. 012071, 2020, doi: 10.1088/1742-6596/1518/1/012071.
- [14] H. A. Zhou dkk., "Generative AI in Industrial Machine Vision -- A review," 2024. [Daring]. Tersedia pada: <https://arxiv.org/abs/2408.10775>

-
- [15] T. Shafira dan A. Fauzy, "Implementasi image classification menggunakan metode Convolutional Neural Network (CNN) pada citra kain tenun," 2021.
- [16] S. Shakya, B. Shrestha, S. Thapa, A. Chauhan, dan S. Adhikari, "Clothes Identification Using Inception ResNet V2 and MobileNet V2," *SSRN Electronic Journal*, Okt 2021, doi: 10.2139/SSRN.3949190.
- [17] T. Hendrawati, D. a. P. Wulandari, I. G. S. S. Dharma, dan C. P. Yanti, "Penerapan deep learning dalam pengenalan Endek Bali menggunakan convolutional Neural network," *Jurnal Media Informatika Budidarma*, vol. 7, no. 4, hlm. 2118, 2023, doi: 10.30865/mib.v7i4.6721.
- [18] W. K. Mutlag, S. K. Ali, Z. M. Aydam, dan B. H. Taher, "Feature extraction methods: a review," *J Phys Conf Ser*, vol. 1591, no. 1, hlm. 012028, 2020, doi: 10.1088/1742-6596/1591/1/012028.
- [19] S. Kirstein, H. Wersing, H. Gross, dan E. Körner, "A Vector Quantization Approach for Life-Long Learning of Categories," dalam *Lecture Notes in Computer Science*, 2009, hlm. 805–812. doi: 10.1007/978-3-642-02490-0_98.
- [20] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, dan Z. Wojna, "Rethinking the inception architecture for computer vision," 2015. [Daring]. Tersedia pada: <https://arxiv.org/abs/1512.00567>
- [21] M. Tan dan Q. V Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," 2015. [Daring]. Tersedia pada: <https://arxiv.org/abs/1905.11946>
- [22] F. Ferdiawan dan N. B. Hartono, "Deteksi Suara Chord Piano Menggunakan Metode Convolutional Neural Network," *Jurnal Informatika Dan Rekayasa Elektronik*, vol. 5, no. 1, hlm. 62–68, 2022, doi: 10.36595/jire.v5i1.552.
- [23] W. Setiawan dan F. Damayanti, "Layers modification of convolutional neural network for pneumonia detection," *J Phys Conf Ser*, vol. 1477, no. 5, hlm. 052055, 2020, doi: 10.1088/1742-6596/1477/5/052055.