

# Analisis Klasifikasi Citra Penokohan Topeng Bali Menggunakan Model EfficientnetV2 Dan Xception

Ni Putu Widya Yuniari<sup>1</sup>, I Made Surya Kumara<sup>2</sup>, I Kadek Agus Wahyu Raharja<sup>3</sup>,  
I Made Adi Bhaskara<sup>4</sup>, Gde Wikan Pradnya Dana<sup>5</sup>, I Gede Wira Darma<sup>6</sup>

<sup>1,2,3,4,5,6</sup> Program Studi Teknik Komputer, Universitas Warmadewa

Jln. Terompong No.24 Sumerta Kelod, Kec Denpasar Timur, Kota Denpasar, Bali 80239

Korespondensi Email: widyayuniari2010@gmail.com

<sup>2</sup>suryakumara33@gmail.com

<sup>3</sup>raharja.wahyu.agus.kadek@gmail.com

<sup>4</sup>adibhaskara39@gmail.com

<sup>5</sup>wikanpdana8044@gmail.com

<sup>6</sup>dewiradarma@gmail.com

**Intisari**—Bali merupakan salah satu Provinsi dengan kekayaan budaya yang sangat kompleks di Indonesia. Salah satunya termanifestasikan dalam citra penokohan topeng Bali. Topeng dalam tradisi Bali tidak hanya diperuntukan sebagai aksesoris pertunjukan saja, melainkan juga menjadi lambang status sosial dalam masyarakat adat, ritus, serta kegiatan-kegiatan primordial tertentu. Setiap detail dalam lekuk pahatan topeng bali menggambarkan sesuatu kekayaan estetika yang terukur sebagai sebuah entitas ontologis. Dalam hal ini besaran keterukuran estetika ini dapat diidentifikasi dengan menggunakan metode komputasi. Penelitian ini mencoba membuat sebuah model machine learning dengan pembelajaran tersupervisi untuk membuat sebuah sistem klasifikasi penokohan topeng Bali. Metode yang digunakan adalah analisis citra dengan mengolah gambar menjadi sebuah vektor numerik tiga dimensi yang masing-masing mewakili indeks warna merah, hijau dan biru. Kemudian masing-masing vektor tersebut akan melalui proses training untuk membuat model dari masing-masing penokohan. Model yang digunakan dalam analisis citra pada penelitian ini adalah EfficientNetV2 dan Xception yang merupakan pengembangan dari model-model konvolusi. Metric pengukuran performa yang digunakan adalah Akurasi, Precision, Recall & F1-Score. Model Xception menghasilkan akurasi sebesar 97%, sementara model EfficientNetV2 bekerja lebih baik dengan menghasilkan akurasi 99%.

**Kata kunci**— Bali, EfficientNetV2, Klasifikasi, Topeng, Xception

**Abstract**— Bali is one of the provinces with quite complex cultural diversity in Indonesia. One of them is the characterization of traditional masks. Traditional masks in Balinese tradition are not only intended as performance accessories, but also as symbols of characterization, social status in indigenous communities, rites, and certain primordial activities. Every detail in the curve of the carving on the Balinese mask indicates an aesthetic richness that is certainly measurable as an ontological entity. In this case, the magnitude of this aesthetic measurability can be assisted by using various computational methods. This study tries to create a machine learning model with supervised learning to create a classification system for Balinese mask characterization. The methods used include: processing mask images into a 3-dimensional vector, each representing the red, green and blue color indices. Then each vector will go through a training process to create a measurability model for each characterization. The models used are EfficientNetV2 and Xception which are developments of convolutional models. The performance measurement metrics used are Accuracy, Precision, Recall & F1-Score. The Xception model produced an accuracy of 97%, while the EfficientNetV2 model produced an accuracy of 99%.

**Keywords**— Bali, Classification, EfficientNetV2, Mask, Xception

## I. PENDAHULUAN

Bali merupakan sebuah provinsi yang memiliki kekayaan budaya paling kompleks sekaligus kaya di Indonesia. Kekayaan ini salah-satunya diukur dengan Indeks Pembangunan Kebudayaan (IPK) yang mencatat nilai tertinggi dari 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 [1]. 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 Jawa dengan indeks sebesar 67,90 [2]. Salah satu komponen penting dalam Indeks Pembangunan Kebudayaan adalah ekspresi budaya yang termanifestasikan dalam berbagai bentuk, salah-satunya adalah topeng tradisional Bali. Topeng dalam antropologi masyarakat Bali tidak hanya merupakan sebuah aksesoris ritus dalam dramatari Bali, melainkan juga sebuah tanda yang melambangkan penokohan manusia melalui pemakaian tokoh-tokoh tertentu [3]. Dalam artian lain, topeng Bali merupakan representasi emosi, status sosial, serta perasaan-perasaan terdalam dari para pengukirnya [4]. Jenis-jenis topeng bali pun sangat beragam, antara lain: topeng barong, topeng rangda, topeng

jangda, topeng jauh, topeng ratu, dan berbagai jenis topeng lainnya [5].

Kajian topeng Bali tidak hanya terbatas pada kajian-kajian antropologis dan kultural semata, melainkan terdapat kajian yang lebih artistik dengan pendekatan estetika [6]. Estetika sendiri adalah sebuah ilmu tentang keindahan. Dalam artian lain, estetika dapat diidentifikasi secara empiris [7]. Keterukuran ini dapat dilihat dalam bentuk indeks warna, bentuk kurva dari setiap detail pahatan yang terbentuk, serta indeks citra yang dihitung sehingga mudah diidentifikasi. Hal ini dikarenakan sebuah citra pada dasarnya adalah sebuah bit-bit data yang membedakannya antara satu dengan yang lain. Salah-satu metode yang sering digunakan adalah metode komputasi (*computational study*) atau menggunakan bantuan Kecerdasan Buatan (AI) [8].

Pendekatan identifikasi citra karakter pada topeng Bali menggunakan kecerdasan buatan dapat dikatakan sebagai sebuah metode yang baru. Hal ini terkait dengan pendokumentasian data yang belum banyak dilakukan. Sehingga belum banyak ditemukan studi terkait. Salah satu studi terbaru (*recent study*) dalam pengidentifikasian topeng tradisional Bali yang dapat dijadikan sebagai acuan menggunakan bantuan kecerdasan buatan, dilakukan oleh Nugraha dkk pada tahun 2023. Studi ini melakukan serangkaian rekognisi pada topeng bali menggunakan model VGG16. Studi ini bertujuan untuk mendapatkan insight tentang nama dan makna budaya yang melekat pada topeng Bali secara programatic. Hal ini mengingat banyaknya topeng bali yang beredar namun memiliki kesamaan yang kompleks secara geometris. Pola geometris itulah yang nanti akan dibaca oleh sistem sebagai sebuah vektor. Studi ini mencoba untuk mengatasi masalah kompleksitas geometris pada topeng Bali dengan mengembangkan sistem Kecerdasan Buatan (AI) yang terintegrasi ke dalam aplikasi seluler menggunakan metode CNN (VGG-16). Hal ini mampu memudahkan pengguna dalam mengidentifikasikan pemaknaan topeng bali dari berbagai model bahkan model ukiran-ukiran terbaru sekalipun [9].

Model dan pendekatan yang sama juga pernah digunakan pada penelitian yang dilakukan oleh Banjaransari dkk pada tahun 2023. Perbedaannya terdapat pada objek kajian berupa wayang tradisional. Penelitian ini mencoba membuat sebuah model klasifikasi citra penokohan wayang menggunakan VGG16 dan MobileNetV2. Penelitian ini mendapatkan hasil precision sebesar 95%, recall 94%, f1-score 94% dan akurasi 94,17% [10].

Studi lain terkait klasifikasi karakteristik topeng bali dilakukan oleh Budiarta & Wiharta pada tahun 2021. Studi ini menggunakan metode bag of visual word dalam proses klasifikasi karakter topeng Bali. Pada metode ini terdapat beberapa algoritma yang digunakan untuk kemudian dilakukan assembling, antara lain: SURF sebagai deteksi fitur, K-Means sebagai proses clustering untuk mendapatkan nilai kuantisasi fitur, dan SVM sebagai klasifikasi karakter topeng Bali. Penelitian ini mendapatkan nilai akurasi sebesar 80% [11].

Studi terakhir yang dapat dijadikan rujukan dari penelitian ini adalah studi yang dilakukan oleh Putri dkk pada tahun 2014. Penelitian ini membuat model Klasifikasi topeng Bali menggunakan algoritma K-Nearest Neighbors (KNN).

Metode yang digunakan adalah pengolahan citra menjadi vektor RGB untuk kemudian dilatih dengan menggunakan jumlah neighbors  $k=3$ . Hasil evaluasi mendapatkan akurasi sebesar 85% [12].

Dari berbagai penelitian terdahulu dapat dikatakan bahwa merekognisi citra penokohan topeng dapat menjadi salah satu media baru dalam pendokumentasian budaya dalam bentuk bit-bit data. Sehingga terjadi alih wahana dari bentuk real menjadi bentuk komputasi. Data-data rekognisi ini kemudian dapat digunakan untuk berbagai keperluan seperti: pembuatan modal 3D dan pembuatan Augmented Reality. Lebih jauh setiap data-data citra juga dapat menjadi standar pendokumentasian yang membedakan satu bentuk ekspresi budaya dengan yang lainnya, sehingga hal ini diharapkan mampu menekan bentuk-bentuk pembajakan, plagiasi, maupun pengakuan identitas dari negara lain.

Berdasarkan urgensi tersebut, penelitian ini akan mencoba membuat sebuah model pengolahan citra berupa sistem klasifikasi yang mampu membaca dan mengklasifikasikan beberapa citra penokohan topeng Bali dengan menggunakan kecerdasan buatan. Penelitian ini akan membandingkan performa dari model EfficientNetV2 dan Xception. Diharapkan nantinya penelitian ini dapat menjadi rujukan, baik untuk penelitian selanjutnya maupun sebagai tolak ukur pembuatan kebijakan bagi para pemangku kepentingan kedepannya dalam pemanfaatan teknologi kecerdasan buatan dalam pendokumentasian, pelestarian dan alih wahana baru kebudayaan khususnya di Provinsi Bali.

## II. STUDI PUSTAKA

Pendekatan identifikasi citra karakter pada topeng Bali menggunakan kecerdasan buatan dapat dikatakan sebagai sebuah metode yang baru. Hal ini terkait dengan pendokumentasian data yang belum banyak dilakukan. Sehingga belum banyak ditemukan studi terkait. Salah satu studi terbaru (*recent study*) dalam pengidentifikasian topeng tradisional Bali yang dapat dijadikan sebagai acuan menggunakan bantuan kecerdasan buatan, dilakukan oleh Nugraha dkk pada tahun 2023. Studi ini melakukan serangkaian rekognisi pada topeng bali menggunakan model VGG16. Studi ini bertujuan untuk mendapatkan insight tentang nama dan makna budaya yang melekat pada topeng Bali secara programatic. Hal ini mengingat banyaknya topeng bali yang beredar namun memiliki kesamaan yang kompleks secara geometris. Pola geometris itulah yang nanti akan dibaca oleh sistem sebagai sebuah vektor. Studi ini mencoba untuk mengatasi masalah kompleksitas geometris pada topeng Bali dengan mengembangkan sistem Kecerdasan Buatan (AI) yang terintegrasi ke dalam aplikasi seluler menggunakan metode CNN (VGG-16). Hal ini mampu memudahkan pengguna dalam mengidentifikasikan pemaknaan topeng bali dari berbagai model bahkan model ukiran-ukiran terbaru sekalipun [9].

Model dan pendekatan yang sama juga pernah digunakan pada penelitian yang dilakukan oleh Banjaransari dkk pada tahun 2023. Perbedaannya terdapat pada objek kajian berupa wayang tradisional. Penelitian ini mencoba membuat sebuah model klasifikasi citra penokohan wayang menggunakan VGG16 dan MobileNetV2. Penelitian ini mendapatkan hasil

precision sebesar 95%, recall 94%, f1-score 94% dan akurasi 94,17% [10].

Studi lain terkait klasifikasi karakteristik topeng bali dilakukan oleh Budiarta & Wiharta pada tahun 2021. Studi ini menggunakan metode bag of visual word dalam proses klasifikasi karakter topeng Bali. Pada metode ini terdapat beberapa algoritma yang digunakan untuk kemudian dilakukan assembling, antara lain: SURF sebagai deteksi fitur, K-Means sebagai proses clustering untuk mendapatkan nilai kuantisasi fitur, dan SVM sebagai klasifikasi karakter topeng Bali. Penelitian ini mendapatkan nilai akurasi sebesar 80% [11].

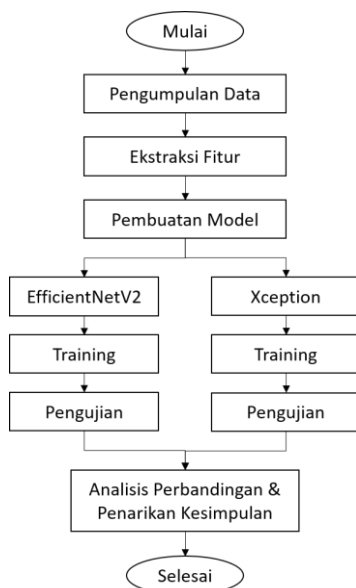
Studi terakhir yang dapat dijadikan rujukan dari penelitian ini adalah studi yang dilakukan oleh Putri dkk pada tahun 2014. Penelitian ini membuat model Klasifikasi topeng Bali menggunakan algoritma K-Nearest Neighbors (KNN). Metode yang digunakan adalah pengolahan citra menjadi vektor RGB untuk kemudian dilatih dengan menggunakan jumlah neighbors  $k=3$ . Hasil evaluasi mendapatkan akurasi sebesar 85% [12].

Dari berbagai penelitian terdahulu dapat dikatakan bahwa merekognisi citra penokohan topeng dapat menjadi salah satu media baru dalam pendokumentasian budaya dalam bentuk bit-bit data. Sehingga terjadi alih wahana dari bentuk real menjadi bentuk komputasi. Data-data rekognisi ini kemudian dapat digunakan untuk berbagai keperluan seperti: pembuatan modal 3D dan pembuatan Augmented Reality. Lebih jauh setiap data-data citra juga dapat menjadi standar pendokumentasian yang membedakan satu bentuk ekspresi budaya dengan yang lainnya, sehingga hal ini diharapkan mampu menekan bentuk-bentuk pembajakan, plagiasi, maupun pengakuan identitas dari negara lain.

### III. METODOLOGI PENELITIAN

#### 3.1 Skema Alur Penelitian

Adapun diagram alir dari penelitian ini dapat dilihat pada Gambar 1.



Gambar 1. Skema Alur Penelitian

Dari Gambar 1 dapat dilihat bahwa penelitian ini dimulai dengan mengumpulkan dataset yang berasal dari penelitian sebelumnya, kemudian dilanjutkan dengan proses ekstraksi fitur yang bertujuan mengubah bentuk citra menjadi bentuk vektor numeric. Kemudian dilanjutkan dengan proses pembuatan model. Model yang digunakan dalam penelitian ini adalah model EfficientNet dan Xception. Lalu kemudian dilanjutkan dengan proses training menggunakan 25 iterasi (epoch) 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.

#### 3.2 Pengumpulan Data

Dataset yang digunakan adalah dataset topeng pajegan bali oleh Surya Pradan yang dapat diakses pada platform kaggle pada url: <https://www.kaggle.com/datasets/suryapradana/balinese-mask>. Dataset ini berisi kumpulan gambar dari topeng pajegan bali yang diklasifikasikan menjadi 7 buah label, yaitu: topeng bujuh, topeng dalam, topeng keras, topeng penasar, topeng sidikarya, topeng tua, dan topeng wijil. Masing-masing data memiliki 50 buah gambar. Beberapa contoh gambar topeng bali yang digunakan pada penelitian ini dapat dilihat pada Gambar 2.



Gambar 2. Dataset Topeng (Dari Kiri Ke Kanan, Atas Ke Bawah): Topeng Bujuh, Topeng Dalam, Topeng Keras, Topeng Penasar, Topeng Sidikarya, Topeng Tua & Topeng Wijil


Sekilas, secara visual beberapa jenis topeng memiliki kesamaan rupa, seperti pada topeng dalam dan topeng keras, lalu pada topeng penasar dengan topeng wijil. Namun kesemua topeng tersebut adalah jenis penokohan topeng yang berbeda. Disinilah model-model komputasi menjadi penting untuk dapat menjadi pembeda yang empiris diantara penokohan topeng-topeng tersebut.

#### 3.3 Ekstraksi Fitur

Ekstraksi fitur adalah proses mengubah data dalam bentuk apapun (dalam hal ini berupa citra gambar) menjadi bentuk vektor numeric yang dapat dibaca oleh program [13]. 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 [14].

Tahap pertama, ukuran gambar akan disesuaikan menjadi 150 pixel x 150 pixel untuk menyamakan node-node pengambilan indeks warna. Kemudian pada setiap pixel akan dilakukan proses color extraction emnggunakan RGB-Extraction. Skema proses RGB-Extraction dapat dilihat pada Gambar 3.



Gambar 3. Proses Color Extraction [14]

Proses pada Gambar 3 dilakukan pada semua node pixel data, sehingga menghasilkan sebuah vektor dengan dimensi 150 x 150 x 3 [15]. Keseluruhan proses ekstraksi fitur dapat dilihat pada Gambar 4.



Gambar 4. Image to Vector

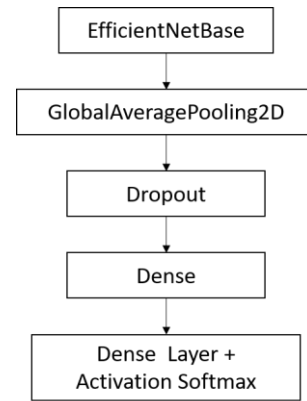
Proses ini kemudian dilakukan pada keseluruhan dataset untuk menghasilkan vektor training.

### 3.4 Arsitektur EfficientNetV2

EfficientNet adalah sebuah model deep learning dengan pendekatan compund scaling yang biasa digunakan untuk melakukan kerja-kerja pengolahan citra [16]. 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 [17]. Matrix ini mengolah dan mencari tau bagian terpenting data dalam sebuah proses yang disebut Pooling [18].

Penelitian ini dilakukan dengan menggunakan arsitektur EfficientNetV2 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 performasi dan meningkatkan efisiensi pada proses pelatihan [19].

Arsitektur lengkap EfficientNetV2 yang digunakan dapat dilihat pada Gambar 5.




Gambar 5. Arsitektur EfficientNet

## 4 .Arsitektur Xception

Xception adalah sebuah model deep learning yang dikembangkan dengan menggunakan kerangka kerja depthwise separable convolutions [20]. Kerangka kerja ini memungkinkan proses-proses konvolusi dilakukan dalam dua langkah, yaitu konvolusi pada tiap kanal dan konfolusi menggunakan filter pada informasi gabungan [21]. Struktur ini digunakan untuk meningkatkan efisiensi performasi dalam pemrosesan citra [22].

Penelitian ini menggunakan model Xception yang sudah direkayasa dengan proses fine tuning dengan menambahkan layer MaxPooling, Flatten, Dense, dan Dropout. Arsitektur lengkap yang digunakan dapat dilihat pada Gambar 6.



Gambar 6. Arsitektur Xception

### 3.5 Proses Training

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 training

dimulai dengan membagi data menjadi data training dan data testing dengan perbandingan 50:50. Data training akan digunakan untuk melakukan proses pelatihan sedangkan data testing akan digunakan sebagai data validasi dan pengujian. Proses training pada kedua model akan dilakukan dengan menggunakan 25 iterasi tanpa melakukan early stopping. Kemudian optimizer yang digunakan adalah Adam dan loss metric yang digunakan adalah Binary Crossentropy.

**3.6 Teknik Analisa 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 7.

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

Gambar 7. 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).

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \tag{1}$$

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).

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

**IV. HASIL DAN PEMBAHASAN**


**4.1 EfficientNet Model**

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 performa akurasi selama proses training pada model EfficientNet dapat dilihat pada Gambar 8.




Gambar 8. Performa Akurasi Selama Proses Training Pada Model EddicientNet

Sementara grafik performa loss selama proses training pada model EfficientNet dapat dilihat pada Gambar 9. Dari kedua grafik diatas tidak ditemukan indikasi overfitting, sehingga model dapat dikatakan valid dan dapat digunakan.



Gambar 9. Performa Loss Metrik Selama Proses Training Pada 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 10.



Gambar 10. Confusion Matrix Pengujian Model EfficientNet

Dari Gambar 10 dapat dilihat bahwa hampir semua data testing dapat diprediksi dengan baik oleh model. Hanya terdapat satu buah kesalahan pada label '7' (Wijil) yang malah diprediksi sebagai label '6' (Tua). Kemudian dari perhitungan precision, recall, dan f1-score pada masing-masing label dapat dilihat pada Tabel 1.


Tabel 1. Hasil Pengujian Model EfficientNet

| Label                | Precision | Recall | F1-Score |
|----------------------|-----------|--------|----------|
| <b>1 (Bujuh)</b>     | 100%      | 100%   | 100%     |
| <b>2 (Dalem)</b>     | 100%      | 100%   | 100%     |
| <b>3 (Keras)</b>     | 100%      | 100%   | 100%     |
| <b>4 (Penasar)</b>   | 100%      | 100%   | 100%     |
| <b>5 (Sidakarya)</b> | 100%      | 100%   | 100%     |
| <b>6 (Tua)</b>       | 96%       | 100%   | 98%      |
| <b>7 (Wijil)</b>     | 100%      | 96%    | 98%      |
| <b>Akurasi</b>       | 99%       |        |          |

Dari Tabel 1 dapat dilihat bahwa mayoritas precision, recall dan f1-score pada setiap label adalah 100%. Kecuali pada label 6 dan label 7. Hal ini disebabkan oleh kesalahan (galat) tipe 2 yang terjadi pada salah-satu data pada label 7 (Wijil). Sementara akurasi final yang dihasilkan adalah 99%.


#### 4.2 Xception Model

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 performa akurasi selama proses training pada model Xception dapat dilihat pada Gambar 11.



Gambar 11. Performa Akurasi Selama Proses Training Pada Model Xception


Sementara grafik performa loss selama proses training pada model Xception dapat dilihat pada Gambar 12.



Gambar 12. Performa Loss Metrik Selama Proses Training Pada Model Xception

Dari kedua grafik diatas tidak ditemukan indikasi overfitting, sehingga model dapat dikatakan valid dan dapat digunakan. 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 Xception dapat dilihat pada Gambar 13.

Dari Gambar 13 dapat dilihat bahwa hampir semua data testing dapat diprediksi dengan baik oleh model. Namun hasilnya masih lebih buruk dibandingkan dengan model EfficientNet. Dari Gambar 13 dapat dilihat bahwa terdapat 3 data pada label '2' (Dalem) yang malah diprediksi sebagai label '6' (Tua). Terdapat 2 data pada label '4' (Penasar) yang malah tidak teridentifikasi. Sementara 1 buah data label '4' (Penasar) lainnya malah diidentifikasi sebagai label '7' (Wijil). Terakhir ada sebuah data label '7' (Wijil) yang malah diprediksi sebagai label '3' (Keras).



Gambar 13. Confusion Matrix Pengujian Model Xception

Kemudian dari perhitungan precision, recall, dan f1-score pada masing-masing label dapat dilihat pada Tabel 2.

Tabel 2. Hasil Pengujian Model Xception

| Label                | Precision | Recall | F1-Score |
|----------------------|-----------|--------|----------|
| <b>1 (Bujuh)</b>     | 100%      | 100%   | 100%     |
| <b>2 (Dalem)</b>     | 100%      | 88%    | 94%      |
| <b>3 (Keras)</b>     | 97%       | 100%   | 98%      |
| <b>4 (Penasar)</b>   | 100%      | 88%    | 93%      |
| <b>5 (Sidakarya)</b> | 100%      | 100%   | 100%     |
| <b>6 (Tua)</b>       | 88%       | 100%   | 94%      |



|                  |     |     |     |
|------------------|-----|-----|-----|
| <b>7 (Wijil)</b> | 96% | 96% | 96% |
| <b>Akurasi</b>   | 97% |     |     |

Dari Tabel 1 dapat dilihat bahwa performa precision, recall dan f1-score cukup beragam. Namun secara keseluruhan hasilnya sedikit lebih buruk daripada performa model EfficientNet. Hal ini bisa terjadi karena beberapa kesalahan prediksi yang merupakan galat tipe 1 dan galat tipe 2 yang terjadi pada beberapa label yang menurunkan performansi. Namun secara keseluruhan, hasil dapat dikatakan sebagai kategori baik dengan akurasi sebesar 97%.

### 4.3 Pembahasan

Dari hasil pemaparan hasil pengujian pada sub-bab 4.1 dan 4.2 dapat dilakukan studi perbandingan untuk model EfficientNet cenderung bekerja lebih baik daripada model Xception jika ditinjau dari metric akurasi, precision, recall dan f1-score dimana keempatnya menunjukkan hasil yang 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 performa tinggi dalam pengolahan citra. Arsitektur dasar EfficientNet juga lebih kompleks dibandingkan dengan Xception, hal ini memungkinkan proses pembelajaran yang lebih dalam. Meskipun demikian, untuk mengimbangnya, proses fine tuning dan transfer learning pada model Xception dibuat lebih panjang daripada EfficientNet. Hal ini bisa dilihat pada perbandingan Gambar 5 dan Gambar 6.

Arsitektur yang lebih kompleks pada base model EfficientNet juga berkontribusi pada proses training yang lebih cepat dalam menemukan fitting point. Hal ini dapat dilihat pada perbandingan Gambar 8 dengan Gambar 11 dimana pada data training, model Efficient Net jauh lebih dahulu mencapai angka 90% dibandingkan dengan model Xception. Kemudian juga untuk data testing, kenaikannya cukup tajam setelah model mendapatkan pola yang fit pada model EfficientNet ketimbang Xception. Namun kompleksitas ini tentunya memiliki kekurangan, yaitu pada resource yang digunakan yang berpengaruh pada waktu yang dibutuhkan pada proses training secara keseluruhan.

### V. KESIMPULAN

Penelitian ini berhasil membuat sebuah model klasifikasi penokohan citra topeng Bali yang terdiri dari: Topeng Bujuh, Topeng Dalem, Topeng Keras, Topeng Penasar, Topeng Sidakarya, Topeng Tua & Topeng Wijil dengan menggunakan ekstraksi fitur image to vector dan model EfficientNet serta Xception. 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 Xception. Dimana model EfficientNet mendapatkan akurasi sebesar 99%, sedangkan Xception hanya mendapatkan akurasi sebesar 97%. Hasil yang sama juga didapati pada metric precision, recall dan f1-score pada setiap label. Dari hasil confusion matrix juga ditemukan bahwa error lebih banyak terjadi pada model Xception daripada model EfficientNet yang berimplikasi pada turunya performa.

Tingginya performa pada model EfficientNet sudah sesuai dengan kerangka tori dimana kompleksitas model EfficientNet dengan kerangka kerja compound scaling akan memberikan proses training yang lebih panjang sehingga berimplikasi pada tingginya performa. Bahkan setelah model Xception diperkaya dengan berbagai layer tambahan, EfficientNet masih menunjukkan performa yang lebih baik.

Secara keseluruhan, penelitian ini berhasil membuktikan bahwa EfficientNet bekerja lebih baik daripada Xception dalam kasus klasifikasi citra penokohan topeng Bali. Namun tentunya masih terdapat beberapa kekurangan yang dapat menjadi saran dan masukan untuk penelitian berikutnya antara lain: gunakan 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 performa pada iterasi tertentu. Hal ini tentunya menghindari pembelajaran berulang yang tidak perlu yang secara simultan dapat mengurangi beban resource.

### REFERENSI

- [1] KEMDIKBUD, "Indeks Pembangunan Kebudayaan," 2024. <https://ipk.kemdikbud.go.id/> (accessed Oct. 01, 2024).
- [2] KEMDIKBUD, *Kebudayaan Dalam Perbandingan: Analisis Komparatif Atas Ipk Dan Enam Indeks Terkait*, 2022nd ed. Jakarta: Kementerian Pendidikan, Kebudayaan, Riset dan Teknologi, 2022.
- [3] A. Kusuma and I. W. Karja, "Unraveling the Sacred Connection: the Sidakarya Mask and Pemuteran Jagad Sidakarya Temple in Balinese Culture," *Int. J. Soc. Sci. Hum. Res.*, vol. 06, 2023, doi: 10.47191/ijsshr/v6-i7-84.
- [4] I. W. Suardana, "Struktur Rupa Topeng Bali Klasik," *Imaji*, vol. 4, no. 1, 2015, doi: 10.21831/imaji.v4i1.6703.
- [5] I. Wayan Mudra, *Topeng Bali*. PUSAT PENERBITAN LP2MPP INSTITUT SENI INDONESIA DENPASAR, 2021. [Online]. Available: <https://repo.isi-dps.ac.id/4541/>
- [6] M. Hobart, "Cultural Studies and Everyday Life: A Balinese Case," *J. Kaji. Bali*, vol. 12, no. 2, pp. 627–647, 2022, doi: 10.24843/JKB.2022.v12.i02.p15.
- [7] M. Nadal and O. Vartanian, "3Empirical Aesthetics: An Overview," in *The Oxford Handbook of Empirical Aesthetics*, Oxford University Press, 2022. doi: 10.1093/oxfordhb/9780198824350.013.1.
- [8] M. Mishra and P. B. Lourenço, "Artificial intelligence-assisted visual inspection for cultural heritage: State-of-the-art review," *J. Cult. Herit.*, vol. 66, pp. 536–550, 2024, doi: <https://doi.org/10.1016/j.culher.2024.01.005>.
- [9] P. G. S. Nugraha Cipta, P. S. Udyana Putra, I. P. A. E. Darma Udayana, and I. P. D. G. Ambara Putra, "Smart Mobile Application for Detecting Balinese Masks to Introduce Balinese Culture to World Tourism," vol. 13, no. 02, pp. 354–365, 2023, [Online]. Available: <http://ejournal.seaninstitute.or.id/index.php/InfoSains>
- [10] M. Banjaransari, A. Prahara, M. Banjaransari, and A. Prahara, "Image Classification of Wayang Using Transfer Learning and Fine-Tuning of CNN Models," *Bul. Ilm. Sarj. Tek. Elektro*, vol. 5, no. 4, pp. 632–641, 2023, doi: 10.12928/biste.v5i4.9977.
- [11] K. Budiarta, D. M. Wiharta, and K. O. Saputra, "Balinese Mask Characters Classification using Bag of Visual Words Model," *J. Electr. Electron. Informatics*, vol. 5, no. 1, p. 25, 2021, doi: 10.24843/jeei.2021.v05.i01.p05.
- [12] N. M. E. A. Putri, I. G. A. G. Arya Kadyanan, I. W. Supriana, C. R. A. Pramarta, A. A. I. N. Eka Karyawati, and I. B. G. Dwidasmara, "Identifikasi Topeng Bali Dengan Metode KNN (K Nearest Neighbor)," *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 11, no. 2, p. 405, 2022, doi: 10.24843/jlk.2022.v11.i02.p19.

- [13] W. Mutlag, S. Ali, Z. Mosad, and B. H. Ghrabat, "Feature Extraction Methods: A Review," *J. Phys. Conf. Ser.*, vol. 1591, p. 12028, 2020, doi: 10.1088/1742-6596/1591/1/012028.
- [14] K. Hafidh, I. Muhimmah, and L. Rosita, "Pemrosesan Citra Digital dalam Klasifikasi Hasil Urinalisis Menggunakan Kamera Smartphone," *J. Inform. dan Rekayasa Elektron.*, vol. 2, no. 1, p. 10, 2019, doi: 10.36595/jire.v2i1.70.
- [15] S. KIRSTEIN, H. WERSING, H. M. GROSS, and E. KÖRNER, "A vector quantization approach for life-long learning of categories," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 5506 LNCS, no. PART 1, pp. 805–812, 2009, doi: 10.1007/978-3-642-02490-0\_98.
- [16] M. Tan and Q. V Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," 2019.
- [17] F. Ferdiawan and B. Hartono, "Deteksi Suara Chord Piano Menggunakan Metode," vol. 5, no. 1, pp. 62–68, 2022.
- [18] M. Ahdi, K. Sjamsuri, A. Kunaefi, B. Nugroho, and A. Yusuf, "Convolutional Neural Network (CNN) EfficientNet-B0 Model Architecture for Paddy Diseases Classification," 2023, pp. 105–110. doi: 10.1109/ICTS58770.2023.10330828.
- [19] S. Rizal, N. Ibrahim, N. Pratiwi, S. Saidah, and R. FU'ADAH, "Deep Learning untuk Klasifikasi Diabetic Retinopathy menggunakan Model EfficientNet," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 8, p. 693, 2020, doi: 10.26760/elkomika.v8i3.693.
- [20] J. O. Carnagie, A. R. Prabowo, E. P. Budiana, and I. K. Singgih, "Essential Oil Plants Image Classification Using Xception Model," *Procedia Comput. Sci.*, vol. 204, pp. 395–402, 2022, doi: <https://doi.org/10.1016/j.procs.2022.08.048>.
- [21] C. Google, "Xception: Deep Learning with Depthwise Separable Convolutions," pp. 1251–1258, 2014.
- [22] C. Tejada and D. Subauste, "Use of Xception Architecture for the Classification of Skin Lesions," vol. 22, no. 3, pp. 20–25, 2024.
- [23] A.P. Astuti, S. Alam, and I. Jaelani, "Komparasi Algoritma Support Vector Machine Dengan Naïve Bayes Untuk Analisis Sentimen Pada Aplikasi BRImo," *Jurnal Bangkit Indonesia*, vol 11, no 2, pp1-6, Oct.2022, doi: 10.52771/bangkitindonesia.v11i2.196.