

## Implementasi Arsitektur *Xception* Dalam Menentukan Kematangan Tandan Buah Segar Kelapa Sawit

Irfan Aryadi<sup>1\*</sup>, Agus Suhendar<sup>2</sup>

Informatika, Universitas Teknologi Yogyakarta, Sleman, Indonesia  
\*e-mail *Corresponding Author*: irfan.5210411264@student.uty.ac.id

### Abstract

*Fresh Fruit Bunches (FFB) of oil palm play a crucial role in the palm oil industry, particularly in determining the quality and quantity of palm oil production. Identifying the maturity level of FFB is a key factor in ensuring optimal production outcomes. This study proposes a method for classifying FFB maturity using the Xception architecture based on Convolutional Neural Networks (CNN). The dataset consists of 1000 images, divided into two categories: 'ripe' and 'unripe'. The preprocessing phase included image augmentation techniques to increase training data variation. Model evaluation was conducted using an 80:20 data split for training and validation. The results showed that the Xception model achieved an accuracy of 99%, with a precision of 0.99, recall of 1.00, and an F1-score of 1.00 for the 'ripe' class. These findings demonstrate the effectiveness of the Xception architecture in FFB maturity classification and suggest potential future development with a larger dataset and Android-based application implementation.*

**Keywords:** *Fresh Fruit Bunches; Classification; Oil Palm; CNN; Xception; Adamax*

### Abstrak

Tandan Buah Segar (TBS) kelapa sawit memainkan peran penting dalam industri kelapa sawit, khususnya dalam menentukan kualitas dan kuantitas hasil produksi minyak sawit. Penentuan tingkat kematangan TBS menjadi aspek kunci untuk memastikan produksi yang optimal. Penelitian ini menawarkan pendekatan klasifikasi kematangan TBS menggunakan arsitektur *Xception* yang didukung oleh jaringan syaraf tiruan *Convolutional Neural Network* (CNN). Dataset yang digunakan berjumlah 1000 gambar, dibagi menjadi dua kategori, yaitu matang dan mentah. Tahapan *preprocessing* dilakukan dengan teknik augmentasi gambar untuk meningkatkan variasi data pelatihan. Evaluasi model menggunakan pembagian data sebesar 80% untuk pelatihan dan 20% untuk validasi. Hasil pengujian menunjukkan bahwa model *Xception* mampu mencapai akurasi hingga 99%, dengan *precision* 0,99, *recall* 1,00, dan *F1-score* 1,00 pada kelas matang. Temuan ini menegaskan kemampuan arsitektur *Xception* dalam melakukan klasifikasi tingkat kematangan TBS, serta berpotensi untuk dikembangkan lebih lanjut dengan dataset yang lebih besar dan diterapkan pada aplikasi berbasis Android.

**Kata kunci:** *Tandan Buah Segar; Klasifikasi; Kelapa Sawit; CNN; Xception; Adamax*

### 1. Pendahuluan

Kelapa sawit (*Elaeis guineensis*) merupakan salah satu komoditas pertanian yang paling penting di dunia, terutama di negara-negara tropis seperti Indonesia dan Malaysia. Kualitas Tandan Buah Segar (TBS) kelapa sawit sangat memengaruhi hasil minyak yang dihasilkan, menjadikan penentuan tingkat kematangan TBS sebagai faktor krusial dalam industri pengolahan kelapa sawit [1]. Saat TBS dipanen pada waktu yang tepat, minyak yang dihasilkan akan memiliki kualitas dan kuantitas yang optimal. Sebaliknya, panen yang dilakukan pada TBS yang belum matang atau belum mencapai tingkat kematangan optimal dapat mengurangi jumlah dan kualitas minyak yang dihasilkan [2]. Saat TBS mencapai kondisi matang, kandungan minyak dalam daging TBS akan meningkat yang dikarenakan proses konversi karbohidrat menjadi lemak dalam buah [3].

Penentuan kematangan TBS dilapangan pada umumnya masih dilakukan secara manual dengan mengandalkan pengalaman dan keahlian petani serta petugas lapangan [4]. Metode tradisional ini sering kali memiliki keterbatasan dalam hal objektivitas, efisiensi, dan

konsistensi, sehingga berpotensi menyebabkan kerugian ekonomi. Dalam praktiknya, penilaian kematangan yang hanya didasarkan pada ciri-ciri eksternal seperti warna buah dapat bersifat subjektif. Oleh karena itu, diperlukan teknologi yang lebih modern dan akurat untuk mengotomatisasi proses penentuan kematangan TBS.

Kemajuan dalam teknologi *deep learning*, khususnya melalui *Convolutional Neural Networks* (CNN), menawarkan solusi yang menjanjikan untuk tugas-tugas klasifikasi gambar, termasuk klasifikasi kematangan TBS. CNN merupakan arsitektur jaringan saraf yang dirancang khusus untuk memproses data berbentuk gambar dan telah menjadi komponen utama dalam berbagai aplikasi *computer vision* [5]. Dengan memanfaatkan lapisan *convolution*, *pooling*, dan *fully connected*, CNN dapat mengenali pola kompleks dalam gambar secara otomatis. Kemampuan CNN untuk secara otomatis belajar dan mengekstraksi fitur menjadikannya alat yang sangat berguna dalam melakukan klasifikasi gambar [6], termasuk dalam mengidentifikasi tingkat kematangan TBS. Salah satu arsitektur CNN yang telah menunjukkan performa unggul adalah *Xception*, yang menggunakan teknik *depthwise separable convolutions* untuk meningkatkan efisiensi dan akurasi. Arsitektur *Xception* menawarkan potensi besar untuk diterapkan dalam klasifikasi tingkat kematangan TBS, karena kemampuannya dalam mengekstraksi fitur yang lebih mendalam dan kompleks.

Penelitian ini bertujuan untuk mengimplementasikan arsitektur *Xception* dalam klasifikasi tingkat kematangan TBS kelapa sawit. Selain itu, penelitian ini juga mengevaluasi kinerja model *Xception* dalam mengklasifikasikan TBS ke dalam kategori matang dan mentah. Dengan hasil yang diharapkan, penelitian ini dapat memberikan solusi teknologi yang dapat mendukung efisiensi dan akurasi penentuan kematangan TBS dalam skala industri, serta membantu meningkatkan produktivitas dan kualitas hasil panen.

## 2. Tinjauan Pustaka

Klasifikasi kematangan Tandan Buah Segar (TBS) kelapa sawit semakin berkembang, terutama dengan penerapan algoritma *machine learning* dan *Convolutional Neural Network* (CNN). Penelitian oleh A. I. Suharjito [7] mengembangkan model *deep learning* untuk menentukan kombinasi parameter optimal dari model *AlexNet*, dengan tujuan meningkatkan kinerja klasifikasi tingkat kematangan TBS. Peneliti menggunakan 6.000 citra TBS kelapa sawit yang dikelompokkan ke dalam enam kelas yang terbagi menjadi TBS Mentah, TBS Mengkal, TBS Matang, TBS Terlalu Matang, TBS *Abnormal*, dan TBS Janjang Kosong. Hasilnya menunjukkan bahwa model *AlexNet*, setelah penerapan teknik *image enhancement* dan *hyperparameter tuning*, berhasil meningkatkan akurasi dari 0,8666 menjadi 0,9530, menunjukkan efektivitas CNN dalam klasifikasi tingkat kematangan kelapa sawit.

Pada penelitian yang dilakukan oleh Triyogi et al [8] bertujuan membangun sistem otomatis untuk mengklasifikasikan kematangan buah kelapa sawit dengan teknologi CNN, yang bertujuan menggantikan penilaian manusia dan meningkatkan efisiensi. Dengan menggunakan dataset yang terdiri dari 300 citra dibagi ke dalam tiga kelas mentah, matang, dan busuk mereka menemukan bahwa dengan menggunakan arsitektur *MobileNet*, hasil terbaik mencapai akurasi 100% pada data pelatihan dan pengujian, serta nilai *loss* yang sangat rendah. Hasil ini menunjukkan potensi CNN dalam klasifikasi tingkat kematangan kelapa sawit.

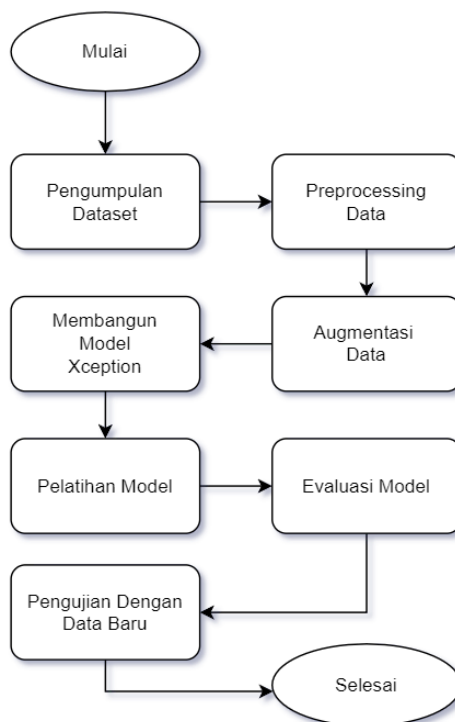
Dalam penelitian lain yang dilakukan oleh Muhammad Ilham Rasyid dan Lulu Mawaddah Wisudawati [9], fokusnya adalah menganalisis klasifikasi hama ulat pada daun sawi dengan menggunakan model *Xception*. Penelitian ini mengusulkan arsitektur *Xception* untuk mengklasifikasi daun sawi yang terdapat hama dan tidak terdapat hama. Mereka melakukan eksperimen dengan berbagai teknik preprocessing, seperti cropping, normalisasi, augmentasi, dan median filtering. Hasil terbaik dicapai dengan skema data 60/20/20, yang menghasilkan akurasi 96%, sensitivitas 96%, dan spesifisitas 97%. Penelitian ini menegaskan pentingnya penggunaan teknik preprocessing yang tepat dan arsitektur yang sesuai untuk meningkatkan performa klasifikasi.

Berdasarkan kelebihan dan kelemahan penelitian-penelitian sebelumnya, penelitian ini memiliki beberapa keunggulan dibandingkan dengan penelitian sebelumnya. Berbeda dengan penelitian yang menggunakan dataset kecil, penelitian ini menggunakan dataset yang lebih besar dan beragam yang diambil langsung dari kebun kelapa sawit, mencakup berbagai kondisi pencahayaan, sudut pengambilan gambar, dan posisi TBS, yang bertujuan untuk meningkatkan generalisasi model dan mengurangi *overfitting*. Selain itu, penelitian ini

mengevaluasi performa model dengan beberapa skenario pembagian dataset yang memberikan pemahaman lebih dalam tentang pengaruh pembagian data terhadap kinerja model. Dengan menggunakan *Xception* dan *depthwise separable convolutions*, penelitian ini meningkatkan efisiensi ekstraksi fitur dan mengurangi jumlah parameter tanpa mengorbankan akurasi. Penggunaan *Adamax* sebagai *optimizer* juga mempercepat konvergensi model. Keunggulan ini menjadikan model lebih efisien dan cocok untuk aplikasi industri yang membutuhkan akurasi cepat. Penelitian ini juga memperkenalkan penggunaan *Xception* yang lebih spesifik untuk klasifikasi kematangan TBS kelapa sawit, yang belum banyak dieksplorasi dalam penelitian kematangan kelapa sawit sebelumnya.

### 3. Metodologi Penelitian

Penelitian ini bertujuan untuk mengklasifikasikan kematangan TBS (Tandan Buah Segar) kelapa sawit menggunakan arsitektur *Xception*. Klasifikasi ini penting karena kematangan TBS secara langsung mempengaruhi kualitas dan nilai ekonomi hasil panen. Dengan memanfaatkan model *Xception*, yang dikenal karena kemampuannya dalam mengekstraksi fitur-fitur kompleks dari gambar [10], penelitian ini bertujuan untuk mencapai akurasi yang lebih tinggi dalam pengenalan kelas mentah dan matang.



Gambar 1. Tahapan Perancangan arsitektur *Xception*

Pada Gambar 1. Tahapan-tahapan perancangan model melibatkan serangkaian langkah sistematis, dimulai dari pengumpulan dataset gambar TBS, kemudian melakukan preprocessing data untuk menyiapkan gambar agar siap digunakan dalam model. Selanjutnya, teknik augmentasi data diterapkan untuk meningkatkan variasi dan jumlah data pelatihan. Setelah itu, model *Xception* dibangun dan dilatih menggunakan dataset yang telah diproses. Pelatihan model dilakukan secara bertahap untuk mencapai akurasi terbaik. Setelah model selesai dilatih, evaluasi dilakukan untuk menilai performa model berdasarkan metrik akurasi. Hasil evaluasi model kemudian digunakan untuk menguji klasifikasi kematangan TBS pada data baru.

#### 3.1. Pengumpulan Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 1000 citra yang dibagi menjadi dua kelas, yaitu mentah dan matang.

Table 1. Dataset TBS kelapa sawit



Pada Table 1. Merupakan gambar TBS kelapa sawit yang diambil secara langsung dari kebun kelapa sawit menggunakan kamera *handphone*. Kelas mentah mencakup citra buah kelapa sawit yang belum mencapai tingkat kematangan optimal, sedangkan kelas matang mencakup citra buah yang telah mencapai tingkat kematangan maksimal. Setiap citra dalam dataset ini memiliki karakteristik visual yang berbeda, yang memungkinkan model untuk belajar membedakan antara kedua tingkat kematangan tersebut.

### 3.2. Preprocessing Data

Tahap *preprocessing* data dilakukan untuk mempersiapkan dataset sebelum digunakan dalam melatih model. Salah satu langkah penting dalam *preprocessing* adalah normalisasi gambar. Tujuan dari normalisasi ini adalah untuk menjamin bahwa seluruh nilai piksel berada dalam rentang yang telah dinyatakan [11]. Normalisasi diatur untuk mengubah rentang nilai piksel gambar dari 0 hingga 255 menjadi 0 hingga 1 dengan metode *rescale*. Hal ini dilakukan untuk meningkatkan efisiensi pelatihan model. Selain itu, tahap ini juga mencakup penyesuaian ukuran gambar menjadi 300x300 piksel untuk memastikan bahwa semua input gambar memiliki dimensi yang konsisten. Dengan langkah-langkah tersebut, *preprocessing* bertujuan

meningkatkan kualitas dataset, mengurangi beban komputasi, dan mempersiapkannya agar optimal untuk pelatihan model.

### 3.3. Augmentasi Data

Augmentasi data merupakan proses yang dilakukan untuk memperbanyak jumlah dan variasi dataset pelatihan dengan menerapkan berbagai jenis transformasi pada gambar [12]. Dalam penelitian ini, augmentasi dilakukan dengan menggunakan teknik seperti rotasi ( $rotation\_range=30$ ), pergeseran horizontal dan vertikal ( $width\_shift\_range=0.2$ ,  $height\_shift\_range=0.2$ ), serta zoom ( $zoom\_range=0.2$ ). Dengan menerapkan transformasi ini, dataset pelatihan diperluas, yang memungkinkan model belajar dari berbagai variasi gambar dan kondisi nyata. Hal ini membantu model menjadi lebih *robust* dan mampu mengenali TBS dalam berbagai situasi, sekaligus mengurangi risiko *overfitting* terhadap data pelatihan.

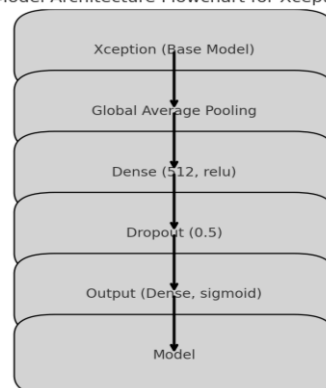
### 3.4. Membangun Model Xception

Dalam penelitian ini, arsitektur *Xception* dipilih sebagai model utama untuk klasifikasi kematangan TBS. Meskipun arsitektur lain seperti *AlexNet* dan *MobileNet* telah digunakan dalam aplikasi klasifikasi gambar sebelumnya. *Xception* adalah arsitektur yang merupakan evolusi dari model *Inception* [13]. *Xception* menawarkan beberapa keuntungan yang signifikan. Salah satu alasan utama pemilihan *Xception* adalah kemampuannya dalam ekstraksi fitur yang lebih efisien melalui penggunaan *depthwise separable convolutions*. *Depthwise separable convolution* terdiri dari dua lapisan, di mana *depthwise convolution* menerapkan filter pada citra input dan *pointwise convolution* menggabungkan hasil dari *depthwise convolution*, sehingga menghasilkan pengurangan beban komputasi secara signifikan [14]. *Xception* hadir dengan arsitektur yang lebih rumit yang mengimplementasikan *depthwise separable convolution*, sehingga menghasilkan model yang lebih efisien dan ringan [15].

*Depthwise convolution* dan *pointwise convolution*, yang tidak hanya mengurangi jumlah parameter yang diperlukan tetapi juga meningkatkan akurasi model dalam mengenali pola-pola kompleks pada gambar. Pada tahap konvolusi *depthwise*, model ini melakukan ekstraksi fitur dengan menerapkan konvolusi secara terpisah untuk setiap saluran warna dalam citra. Hal ini memungkinkan model untuk mengidentifikasi pola dan fitur yang ada dalam citra dengan lebih efisien. Setelah tahap konvolusi *depthwise*, tahap konvolusi *pointwise* menggabungkan fitur-fitur yang diekstraksi untuk membentuk representasi yang lebih lengkap dari citra. Dengan struktur ini, *Xception* mengurangi jumlah parameter yang dibutuhkan dibandingkan dengan arsitektur lain, sehingga menghemat penggunaan memori dan waktu komputasi.

*Xception* juga dirancang untuk menangkap informasi yang lebih kompleks dari citra berkat kedalaman arsitekturnya, yang memungkinkan model untuk belajar dari data dalam bentuk yang lebih mendalam. Oleh karena itu, arsitektur *Xception* dipilih untuk penelitian ini, karena kemampuannya yang tinggi dalam melakukan klasifikasi citra, serta efisiensinya dalam penggunaan sumber daya komputasi.

Model Architecture Flowchart for Xception



Gambar 2. Arsitektur *Xception*

Gambar 2. Merupakan arsitektur yang dirancang dan akan digunakan dalam mengklasifikasi kematangan TBS kelapa sawit. Dalam membangun model *Xception* melibatkan penggunaan arsitektur yang telah terbukti efektif dalam pengenalan gambar. Model *Xception* diimpor dengan parameter *include\_top=False* untuk tidak menyertakan lapisan atas yang tidak relevan. *Input shape* untuk model ditentukan sebagai (300, 300, 3), sesuai dengan ukuran gambar yang telah diproses. Selanjutnya, lapisan *global average pooling* ditambahkan untuk memproses *output* dari model dasar, diikuti oleh lapisan *dense* yang terdiri dari 512 *neuron* dengan fungsi aktivasi *ReLU*. Sebelum lapisan *output* akhir, yang berfungsi untuk menghasilkan klasifikasi *biner*, diterapkan *dropout* dengan rasio 0,5 untuk mengurangi risiko *overfitting*. Lapisan *output* akhir menggunakan fungsi aktivasi *sigmoid*, yang mengubah hasil menjadi probabilitas [16], memungkinkan model untuk menentukan kelas mana yang lebih mungkin untuk dipilih dalam pengambilan keputusan klasifikasi. Dengan konfigurasi ini, model *Xception* siap untuk dilatih.

### 3.5. Pelatihan Model

Pada tahap pelatihan model, proses dilakukan dengan menggunakan *optimizer Adamax* yang telah ditetapkan sebelumnya, bersamaan dengan *learning rate* 0.005. Proses pelatihan berlangsung selama 20 *epoch*, di mana pada setiap *epoch* model belajar dari data pelatihan dan mengoptimalkan bobotnya berdasarkan *loss function* yaitu *binary crossentropy*. Selama pelatihan, model juga dievaluasi pada data validasi untuk memantau kinerjanya, sehingga dapat dilakukan penyesuaian jika diperlukan. Dengan pendekatan ini, diharapkan model dapat mencapai akurasi yang baik dalam mengklasifikasikan tingkat kematangan TBS kelapa sawit, serta mampu meminimalkan risiko *overfitting* melalui pemantauan kinerja pada data yang tidak terlihat selama pelatihan.

### 3.6. Evaluasi Model

Tahapan evaluasi dalam klasifikasi TBS kelapa sawit bertujuan untuk menilai sejauh mana model klasifikasi dapat mengenali tingkat kematangan TBS dengan akurat dan efisien. Dan untuk mengukur kinerja model terhadap hyperparameter [17]. Metode evaluasi yang diterapkan dalam penelitian ini meliputi *Confusion Matrix*, yang digunakan untuk menghitung berbagai metrik evaluasi melalui perbandingan antara kelas yang diprediksi dan kelas yang sebenarnya dalam data uji, serta membantu menganalisis jenis kesalahan yang mungkin muncul dalam prediksi model. Selain itu, penelitian ini menggunakan metrik *F1 score*, *precision*, dan *recall*, yang dihitung dengan rumus 1, 2, dan 3.

$$Precision_{class} = \frac{TP}{TP + FP} \quad (1)$$

$$Recall_{class} = \frac{TP}{TP + FN} \quad (2)$$

$$F1 - Score_{class} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

*Precision* mengukur proporsi prediksi positif yang benar dibandingkan dengan total prediksi positif yang dihasilkan, memberikan gambaran tentang akurasi model dalam mengklasifikasikan TBS yang matang.

*Recall*, atau sensitivitas, mengukur kemampuan model dalam mendeteksi kelas positif dari total jumlah sebenarnya kelas positif, sehingga penting untuk menilai efektivitas model dalam mengidentifikasi TBS yang matang.

*F1-Score*, sebagai nilai rata-rata harmonis dari *precision* dan *recall*, memberikan gambaran yang seimbang mengenai kinerja model dalam mengklasifikasikan kelas positif, terutama ketika terdapat ketidakseimbangan antara kelas positif dan negatif. Terakhir, *Support* menunjukkan jumlah contoh aktual dari masing-masing kelas dalam dataset, yang memberikan konteks dan ukuran untuk setiap kelas yang dievaluasi.

Secara keseluruhan, metrik evaluasi ini memberikan pandangan yang komprehensif tentang performa model dalam klasifikasi TBS kelapa sawit dan berfungsi sebagai dasar untuk perbaikan model di masa yang akan datang.

### 3.7. Pengujian Dengan Data Baru

Tahapan pengujian dengan data baru dilakukan untuk mengevaluasi kemampuan model dalam mengklasifikasikan TBS kelapa sawit yang belum pernah dilihat sebelumnya. Proses ini dimulai dengan memuat model yang telah dilatih. Selanjutnya, gambar yang akan diuji diambil dari folder sebagai inputan, di mana hanya gambar dengan format .jpg, .jpeg, dan .png yang diambil. Setelah gambar diidentifikasi, setiap gambar dimuat dan diubah ukurannya menjadi 300x300 piksel untuk disesuaikan dengan input model. Gambar kemudian diubah menjadi *array* dan dinormalisasi dengan membagi nilainya dengan 255.0 untuk mendapatkan nilai antara 0 dan 1. Setelah itu, dimensi tambahan ditambahkan pada *array* untuk memastikan format yang sesuai untuk input model. Setelah gambar diproses, model melakukan prediksi untuk menentukan kelas dari gambar tersebut. Hasil prediksi dikonversi menjadi label kelas yang sesuai, yaitu "matang" atau "mentah," dengan menerapkan *threshold* 0.5. Prediksi ini kemudian ditampilkan bersamaan dengan gambar, sehingga memberikan gambaran visual yang jelas tentang performa model.

## 4. Hasil dan Pembahasan

### 4.1 Hyperparameter dan Alokasi Data

Pada penelitian ini, pengaturan hyperparameter dan alokasi data dilakukan dengan cermat untuk mengoptimalkan performa model *Xception* dalam mengklasifikasikan tingkat kematangan TBS kelapa sawit.

Table 2. *Hyperparameter* yang digunakan

| Parameter                  | Nilai                      |
|----------------------------|----------------------------|
| Arsitektur                 | <i>Xception</i>            |
| <i>Image Size</i>          | 300x300                    |
| <i>Batch Size</i>          | 64                         |
| <i>Learning rate</i>       | 0.005                      |
| Optimizer                  | <i>Adamax</i>              |
| <i>Epoch</i>               | 20                         |
| <i>Drop Out</i>            | 0.5                        |
| <i>Function Activation</i> | <i>Sigmoid</i>             |
| <i>Loss Function</i>       | <i>Binary Crossentropy</i> |

Table 2. Merupakan hyperparameter yang digunakan dalam perancangan model *Xception*. *Input* gambar diatur menjadi 300x300 piksel untuk memastikan kesesuaian dengan arsitektur *Xception*, yang terkenal efisien dalam mengekstraksi fitur dari gambar. Model dilatih menggunakan optimizer *Adamax*, dengan *learning rate* yang ditetapkan pada 0.005, memberikan stabilitas dan efisiensi dalam konvergensi. Penggunaan *batch size* sebesar 64 mempercepat proses pelatihan, memungkinkan model untuk memproses banyak data sekaligus. Selama 20 *epoch*, model belajar dari data yang diberikan, dengan perhatian khusus untuk mencegah overfitting melalui penerapan *dropout* sebesar 0.5 pada lapisan *fully connected* sebelum *output*.

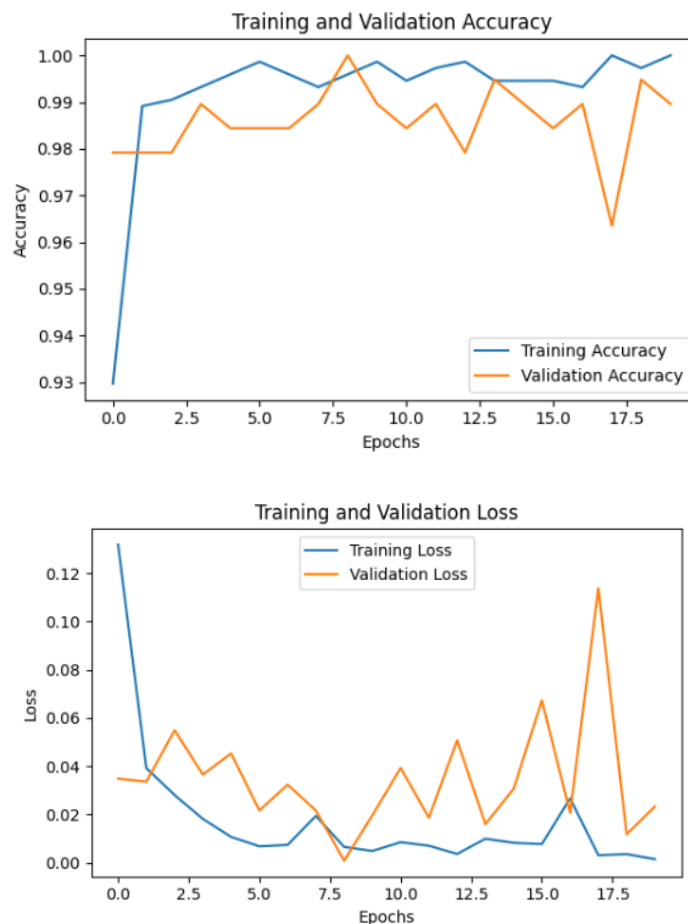
Table 3. Alokasi Data pada setiap eksperimen

| Eksperimen | Data Latih | Data Validasi |
|------------|------------|---------------|
| 1          | 80%        | 20%           |
| 2          | 70%        | 30%           |
| 3          | 60%        | 40%           |

Dapat dilihat dalam Table 4. Eksperimen dilakukan sebanyak tiga eksperimen dengan pembagian dataset yang berbeda untuk data latih dan validasi. Pada eksperimen pertama, data dibagi menjadi 80% untuk pelatihan dan 20% untuk validasi. Eksperimen ini bertujuan untuk memberikan data pelatihan yang lebih besar guna meningkatkan kemampuan model dalam mengenali pola. Pada eksperimen kedua, pembagian dilakukan dengan 70% data pelatihan dan 30% data validasi untuk mengevaluasi pengaruh penggunaan lebih banyak data validasi terhadap performa model. Sementara itu, pada eksperimen ketiga, dataset dibagi dengan 60% untuk pelatihan dan 40% untuk validasi untuk melihat apakah model masih dapat memberikan hasil yang baik dengan data pelatihan yang lebih sedikit.

#### 4.2 Hasil Pelatihan Model

Pada eksperimen pertama, dataset dibagi dengan rasio 80:20, di mana 80% data digunakan untuk pelatihan dan 20% untuk validasi.



Gambar 3. Grafik *Accuracy* dan *Loss* pada eksperimen pertama

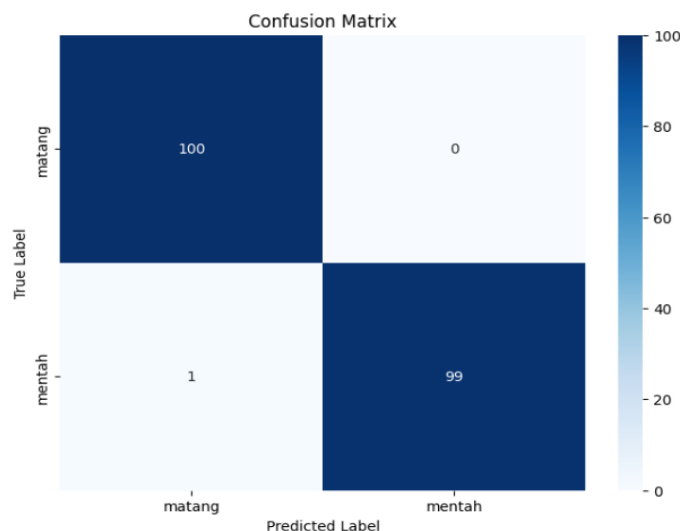
Pada pelatihan model *Xception* yang ditunjukkan pada Gambar 3. Mendapatkan hasil setiap *epoch* menunjukkan penurunan yang signifikan pada nilai *loss* dan peningkatan akurasi. Model mulai dengan akurasi 92.97% pada *epoch* pertama dan meningkat secara konsisten hingga mencapai akurasi 100% pada *epoch* ke-18. Selama proses pelatihan, model menunjukkan kemampuan yang baik dalam mempelajari fitur-fitur dari dataset, dengan nilai *loss* yang menurun dari 0.1318 pada *epoch* pertama hingga 0.0015 pada *epoch* terakhir. Hal ini menunjukkan bahwa model tidak hanya belajar dengan baik dari data pelatihan tetapi juga mampu melakukan generalisasi dengan baik terhadap data validasi, yang terlihat dari akurasi validasi yang cukup tinggi. Keberhasilan model dalam mencapai akurasi yang tinggi dengan pembagian 80:20 menunjukkan bahwa alokasi data ini efektif dalam memberikan data pelatihan yang cukup besar untuk mengoptimalkan kinerja model *Xception* dalam klasifikasi tingkat



kematangan TBS kelapa sawit. Hasil pelatihan ini menjadi dasar untuk evaluasi lebih lanjut dan pengujian dengan data baru pada tahap selanjutnya.

### 4.3 Hasil Evaluasi Model

Setelah menyelesaikan pelatihan model *Xception* pada eksperimen pertama dengan pembagian dataset 80:20, evaluasi dilakukan untuk menilai kinerja model pada data validasi. Dalam eksperimen ini, 80% dari dataset digunakan untuk melatih model, sementara 20% sisanya digunakan untuk pengujian. Hasil evaluasi menunjukkan bahwa model berhasil mencapai akurasi yang sangat tinggi, yaitu 99%, dengan nilai loss yang rendah sebesar 0.0225. Hal ini menandakan bahwa model memiliki kemampuan yang sangat baik dalam mengenali pola pada data.



Gambar 4. Hasil *Confusion Matrix*

Dapat dilihat pada Gambar 4. Hasil *Confusion Matrix* dari evaluasi ini memberikan gambaran yang jelas tentang kinerja klasifikasi model. Dari total 200 gambar yang diuji, model secara akurat mengklasifikasikan 100 gambar sebagai matang tanpa kesalahan, sementara satu gambar matang salah diklasifikasikan sebagai mentah. Di sisi lain, model juga mengenali 99 dari 100 gambar mentah dengan benar. Ini menunjukkan bahwa model *Xception* memiliki tingkat kesalahan yang sangat rendah dalam klasifikasi, yang sangat penting dalam aplikasi praktis. Dari hasil *confusion matrix* yang ditampilkan sebelumnya, model menunjukkan keakuratan tinggi dalam mengklasifikasikan kedua kelas, dengan *false positives* dan *false negatives* yang sangat minim. Pada gambar-gambar yang diuji, satu gambar matang yang salah diklasifikasikan sebagai mentah dan satu gambar mentah yang salah diklasifikasikan sebagai matang. Meskipun ada sedikit kesalahan, ini menunjukkan bahwa model *Xception* mampu meminimalkan kesalahan klasifikasi dalam skenario dunia nyata, di mana kondisi gambar bisa bervariasi.

Classification Report:

|              | precision | recall | f1-score | support |
|--------------|-----------|--------|----------|---------|
| matang       | 0.99      | 1.00   | 1.00     | 100     |
| mentah       | 1.00      | 0.99   | 0.99     | 100     |
| accuracy     |           |        | 0.99     | 200     |
| macro avg    | 1.00      | 0.99   | 0.99     | 200     |
| weighted avg | 1.00      | 0.99   | 0.99     | 200     |

Gambar 5. Hasil *Classification Report*

Hasil *Classification Report* pada Gambar 5 menunjukkan hasil yang menggembirakan, dengan nilai *precision*, *recall*, dan *f1-score* yang sangat tinggi untuk kedua kelas. Kelas matang mencapai *precision* dan *recall* masing-masing sebesar 0.99, sementara kelas mentah hampir sempurna dengan nilai *precision* dan *recall* mendekati 1.00. Hal ini menunjukkan bahwa model tidak hanya efektif dalam mengklasifikasikan gambar-gambar tersebut, tetapi juga mampu melakukan generalisasi dengan baik terhadap data yang belum pernah dilihat sebelumnya.

Table 4. Hasil Evaluasi data pada setiap eksperimen


| Eksperimen | Alokasi Data | Val Loss | Val Accuracy | Precision | Recall | F1-score | Support |
|------------|--------------|----------|--------------|-----------|--------|----------|---------|
| 1          | 80:20        | 0.0225   | 0.9900       | 0.99      | 1.00   | 1.00     | 100     |
| 2          | 70:30        | 0.0564   | 0.9767       | 0.99      | 0.96   | 0.98     | 150     |
| 3          | 60:40        | 0.0417   | 0.9825       | 0.99      | 0.96   | 0.98     | 200     |

Berdasarkan data hasil eksperimen pada Tabel 4. Eksperimen pertama dengan alokasi data 80:20 menunjukkan nilai validasi *loss* terendah sebesar 0.0225 dan akurasi validasi tertinggi sebesar 99%. Selain itu, *precision* mencapai 0.99, sedangkan *recall* maksimal di 1.00, yang menunjukkan bahwa semua contoh kelas matang berhasil diidentifikasi dengan benar. Pada eksperimen kedua dengan alokasi 70:30, meskipun *precision* tetap 0.99, *recall* menurun menjadi 0.96, yang berarti ada beberapa contoh kelas yang tidak terdeteksi. Eksperimen ketiga dengan alokasi 60:40 menunjukkan validasi *loss* 0.0417 dan akurasi 98.25%, dengan *precision* dan *recall* masing-masing 0.99 dan 0.96. Hal ini menunjukkan bahwa alokasi data berpengaruh signifikan terhadap performa model, di mana skema 80:20 memberikan hasil terbaik dalam hal klasifikasi. Dapat disimpulkan bahwa pengembangan model dengan skema pelatihan dan validasi yang tepat sangat penting untuk meningkatkan akurasi dan efektivitas klasifikasi citra. *Performance metrics* seperti *precision*, *recall*, dan *F1-score* yang tinggi pada *classification report* mengindikasikan bahwa model tidak hanya akurasi, tetapi juga keakuratan dalam mendeteksi kedua kelas dengan baik. *Precision* yang hampir mendekati 1 menunjukkan bahwa hampir semua prediksi kelas matang dan mentah adalah benar, sedangkan *recall* yang tinggi mengindikasikan bahwa model juga berhasil mengenali sebagian besar gambar dari kedua kelas tersebut.

#### 4.4 Hasil Pengujian Dengan Data Baru

Pengujian dengan data baru dilakukan dengan cara menyimpan model yang sudah dilatih. Setelah model disimpan lalu model di *import* kembali untuk melakukan prediksi pada gambar baru yang tidak ada di dalam dataset.

Table 5. Data hasil pengujian dengan data baru

| Output Klasifikasi   | Prediksi Kelas | Status Prediksi |
|--|----------------|-----------------|
| Predicted class: matang<br> | Matang         | Benar           |

| Output Klasifikasi   | Prediksi Kelas | Status Prediksi |
|--|----------------|-----------------|
| Predicted class: mentah<br>   | Mentah         | Benar           |
| Predicted class: mentah<br>   | Mentah         | Benar           |
| Predicted class: matang<br>  | Matang         | Benar           |
| Predicted class: matang<br> | Matang         | Benar           |
| Predicted class: mentah<br> | Mentah         | Benar           |

Dalam Tabel 5, dapat dilihat bahwa model berhasil memberikan prediksi yang benar pada semua 6 gambar yang diuji. Dari 6 gambar yang diuji, 3 gambar berhasil diklasifikasikan sebagai matang, dan 3 gambar lainnya sebagai mentah. Semua prediksi ini sesuai dengan kelas yang sebenarnya, menunjukkan bahwa model dapat mengenali dengan baik pola kematangan TBS dalam gambar baru yang tidak ada dalam dataset pelatihan.

#### 4.5 Pembahasan

Penelitian ini memberikan kontribusi signifikan terhadap pengembangan model klasifikasi tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit dengan menggunakan model *Xception*. Salah satu penguatan utama penelitian ini adalah penggunaan dataset yang lebih besar dan lebih beragam. Dataset yang digunakan dalam penelitian ini mencakup berbagai kondisi pencahayaan, posisi TBS, dan sudut pengambilan gambar, yang memungkinkan model untuk lebih mampu menggeneralisasi data baru. Ini berbeda dengan penelitian Triyogi et al sebelumnya yang menggunakan dataset terbatas, yang mungkin menyebabkan model kesulitan dalam mengklasifikasikan gambar dari kondisi yang berbeda.

Selain itu, penelitian ini menggunakan *Xception*, yang memiliki *depthwise separable convolutions* untuk mengurangi jumlah parameter dan meningkatkan efisiensi ekstraksi fitur. Teknik ini lebih efisien dibandingkan dengan model CNN lain seperti *MobileNet* yang diterapkan oleh Triyogi et al pada penelitian sebelumnya, karena *Xception* mampu mengatasi kompleksitas data gambar yang lebih besar dan lebih beragam tanpa mengorbankan akurasi. Hal ini memungkinkan model untuk lebih cepat dan lebih efisien dalam memproses gambar TBS kelapa sawit.

Pada penelitian yang dilakukan oleh A. I. Suharjito menggunakan klasifikasi multikelas dengan enam kelas. Berbeda dengan penelitian ini yang berfokus pada klasifikasi *biner* antara TBS mentah dan matang, yang lebih relevan untuk kebutuhan praktis di industri kelapa sawit. Fokus pada klasifikasi biner ini memungkinkan model untuk memberikan prediksi yang lebih cepat dan lebih akurat dalam konteks aplikasi industri.

Eksperimen yang dilakukan dengan beberapa skenario pembagian dataset 80:20, 70:30, dan 60:40 memberikan wawasan yang lebih mendalam tentang bagaimana pembagian data dapat memengaruhi performa model. Pembagian data yang lebih besar untuk pelatihan terbukti memberikan hasil yang lebih optimal dalam hal akurasi dan pengenalan pola pada data validasi, yang memperkuat pemahaman tentang pentingnya pengaturan data yang tepat dalam pelatihan model.

Secara keseluruhan, penelitian ini memperkenalkan solusi baru dalam klasifikasi TBS kelapa sawit dengan menggunakan *Xception*, serta menunjukkan bahwa dataset yang lebih besar dan lebih beragam dapat meningkatkan performa model secara signifikan. Hasil yang diperoleh juga menunjukkan bahwa *Xception* adalah pilihan yang sangat efektif untuk tugas klasifikasi gambar yang kompleks seperti kematangan TBS, yang memberikan kontribusi besar dalam perkembangan teknologi *deep learning* untuk aplikasi industri.

#### 5. Simpulan

Berdasarkan hasil penelitian mengenai klasifikasi kematangan TBS kelapa sawit menggunakan arsitektur *Xception*, dapat disimpulkan bahwa model ini berhasil mencapai akurasi tinggi dengan nilai validasi mencapai 99% pada skema pembagian data 80:20, dengan loss sebesar 0.0225. Model ini menunjukkan performa yang baik dengan *precision* sebesar 99%, *recall* 100%, dan *F1-score* mencapai 100% untuk kelas matang. Sementara itu, untuk kelas mentah, *precision* dan *recall* masing-masing sebesar 100% dan 99%, dengan *F1-score* sebesar 99%. Hasil evaluasi ini menunjukkan bahwa model mampu melakukan klasifikasi dengan sangat baik.

Untuk pengembangan ke depan, diharapkan menggunakan dataset yang lebih besar dan diimplementasi ke dalam aplikasi *Android* guna memudahkan pengguna dalam pengenalan kematangan TBS di lapangan. Dengan demikian, penelitian ini tidak hanya berkontribusi pada pemahaman mengenai klasifikasi citra, tetapi juga membuka peluang untuk inovasi teknologi dalam pengelolaan hasil pertanian, yang pada gilirannya dapat meningkatkan produktivitas dan efisiensi di sektor perkebunan kelapa sawit.

#### Daftar Referensi

- [1] N. Evitarina and K. Kusriani, "Maturity Classification Methods for Palm Oil Fresh Fruit Bunch: A Systematic Review", *G-Tech*, vol. 8, no. 4, pp. 2324–2333, Oct. 2024
- [2] I. Susanti dan F. Lestari, "Pengaruh Waktu Penundaan Pengolahan Buah Sawit *Elaeis guineensis* Terhadap Mutu Crude Palm Oil dengan Alat Pengolahan Sawit Tipe Batch," *Jurnal Biosilampari: Jurnal Biologi*, vol. 3, no. 2, pp. 56-64, 2021.

- [3] A.L. Siregar, et al., "Korelasi TBS Inti dan TBS Masyarakat terhadap Rendemen Minyak Kelapa Sawit di Kotawaringin Lama, Kalimantan Tengah," *Jurnal AGRIFOR*, vol. 23, no. 2, pp. 241-252, 2024.
- [4] S. Nirmala dan T. Irismawan, "Sistem Pemilah Otomatis Tingkat Kematangan Buah Kelapa Sawit Menggunakan Metode Logika Fuzzy Mamdani Dan Sensor TCS3200," *Journal of Computer System and Informatics (JoSYC)*, vol. 5, no. 1, pp. 144-154, 2023.
- [5] M.A.R. Ramadhan, T.A.N. Ananta, A.A.Zakkyfriza, I.H. Vaviansyah, and Y.N. Fauzan, "Perbandingan Jumlah Layer Pada Convolutional Neural Network Untuk Meningkatkan Akurasi Dalam Klasifikasi Gambar", *Merkurius*, vol. 2, no. 5, pp. 211–217, Jul. 2024.
- [6] A. Putri, S. Suroso, and A. Handayani, "Penerapan EfficiencyNet Untuk Pembuatan Model CNN Pada Klasifikasi Bahasa Isyarat", *bits*, vol. 6, no. 2, pp. 758-766, Sep. 2024.
- [7] A. I. Suharjito, "Perbaikan Model AlexNet untuk Mendeteksi Kematangan TBS Kelapa Sawit dengan Menggunakan Image Enhancement dan Hyperparameter Tuning," *Jurnal Ilmiah Teknologi dan Rekayasa*, vol. 27, no. 1, pp. 56-68, 2022.
- [8] R. Triyogi, R. Magdalena, and B. Hidayat, "Mendeteksi Kematangan Buah Kelapa Sawit Menggunakan Convolutional Neural Network Deep Learning," *Jurnal Nasional SAINS dan TEKNIK*, vol. 1, no. 1, 2023.
- [9] M. I. Rasyid and L. M. Wisudawati, "Klasifikasi Hama Ulat Pada Citra Daun Sawi Berbasis Convolutional Neural Network Dengan Model *Xception*" *Jutisi: Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi*, vol. 13, no. 2, 2024. doi: 10.35889/jutisi.v13i2.1801.
- [10] Y. K. Bintang and H. Imaduddin, "Pengembangan Model *Deep learning* untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning," *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, vol. 9, no. 3, pp. 1442-1455, 2024. doi: <https://doi.org/10.29100/jupi.v9i3.5588>.
- [11] M. Santoso, S. Defit, and Yuhandri, "Application of Convolutional Neural Network in Malay Woven Fabric Pattern Image Classification", *CoSciTech*, vol. 5, no. 1, pp. 177-184, May 2024.
- [12] M. Toyib et al., "Penerapan Algoritma CNN Untuk Mendeteksi Tulisan Tangan Angka Romawi dengan Augmentasi Data", *Algoritma*, vol. 2, no. 3, pp. 108–120, May 2024.
- [13] A. Tirtana, M. G. T. Febriani, D. I. Masrui, and A. A. Aisyah, "Herbify: Aplikasi Perangkat Bergerak Berbasis Komputasi Awan Untuk Mengidentifikasi Tanaman Herbal Indonesia Menggunakan CNN Model *Xception*," *Jurnal Ilmiah Educativ*, vol. 8, no. 1, pp. 1-10, Nov. 2021.
- [14] Z. Syahputra, "Penerapan SSD-MobileNet Dalam Identitas Jenis Buah Apel", *INDOTECH*, vol. 1, no. 1, pp. 1–7, Apr. 2023.
- [15] N. Chandra, "Analisis Performa Akurasi Klasifikasi Citra Jenis Sayur Salada Menggunakan Arsitektur VGG16, *Xception* dan NasNetMobile," *Jurnal Media Informatika Budidarma*, vol. 8, no. 3, p. 1240, 2024.
- [16] A. Pratama, H. Sunardi, and R. M. Fajri, "Efektivitas Penggolongan Kendaraan dengan Metode CNN pada Sistem Transaksi di Gerbang Tol," *Journal of Intelligent Networks and IoT Global*, vol. 2, no. 1, pp. 1-10, Jul. 2024. doi: 10.36982/jinig.v2i1.4435. Available: <https://ejournal.uigm.ac.id/index.php/JINIG/article/view/4435>.
- [17] K.B.V. Putra, I.P.A. Bayupati, and D.M.S. Arsa, "Klasifikasi Citra Daging Menggunakan *Deep learning* dengan Optimisasi Hard Voting", *J. RESTI (Rekayasa Sist. Teknol. Inf.)*, vol. 5, no. 4, pp. 656 - 662, Aug. 2021.