

Deep Learning Menggunakan Algoritma Xception dan Augmentasi Flip Pada Klasifikasi Kematangan Sawit

Fathan Fanrita Masaugi, Febi Yanto*, Elvia Budianita, Suwanto Sanjaya, Fadhilah Syafria

Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: ¹12050116900@studens.uin-suska.ac.id, ^{2,*}febiyanto@uin-suska.ac.id, ³elvia.budianita@uin-suska.ac.id,

⁴suwantosanjaya@uin-suska.ac.id, ⁵fadhilah.syafria@uin-suska.ac.id

Email Penulis Korespondensi: febiyanto@uin-suska.ac.id

Abstrak—Kelapa sawit merupakan salah satu komoditas penting di Indonesia, terlebih Indonesia merupakan negara pengekspor minyak sawit tertinggi di dunia. Kematangan buah sawit ditandai dengan perubahan warna pada buah dari hitam menjadi warna kuning kemerahan. Selain itu, buah sawit yang tidak matang berpengaruh negatif dan signifikan terhadap hasil produksi CPO. Proses pengumpulan data dilakukan dengan mengambil langsung gambar buah sawit pada perkebunan kelapa sawit dan data yang didapatkan dari Kaggle. Jumlah keseluruhan data yaitu 1000 gambar dan 1000 data hasil augmentasi flip. Algoritma Xception merupakan salah satu algoritma dalam deep learning yang merupakan kepanjangan dari Extreme version of Inception. Kombinasi tersebut kemudian terbukti memberikan akurasi yang lebih baik dalam melakukan klasifikasi gambar suatu dataset. Optimizer yang digunakan merupakan optimizer pada tensorflow yaitu Adam (*Adaptive Moment Estimation*) dengan menggunakan nilai learning rate dan dropout. Citra sawit matang dan tidak matang dilakukan klasifikasi dengan menggunakan algoritma Xception dengan data augmentasi dan tanpa augmentasi. Selain itu, dilakukan percobaan dengan mengubah nilai parameter nilai learning rate 0,1, 0,01, 0,001 dan dropout 0,1, 0,01, 0,001. Didapatkan pembagian data (90;10) akurasi terbaik mencapai 95%, Parameter uji yang dilakukan dengan mencobakan terbukti dapat meningkatkan akurasi jika dibandingkan dengan tanpa menggunakan parameter dan augmentasi flip. Akurasi terbaik model Xception 95% pada data yang diberi augmentasi dengan learning rate 0,001 dan dropout 0,1.

Kata Kunci: Xception; CNN; Augmentasi Flip; Adam; Kematangan Sawit

Abstract—Palm oil is an important commodity in Indonesia, especially as Indonesia is the highest palm oil exporting country in the world. Ripe palm fruit is marked by a change in color of the fruit from black to reddish yellow. Apart from that, immature palm fruit has a negative and significant effect on CPO production. The data collection process was carried out by directly taking pictures of palm fruit on oil palm plantations and data obtained from Kaggle. The total amount of data is 1000 images and 1000 data resulting from flip augmentation. The Xception algorithm is an algorithm in deep learning which stands for Extreme version of Inception. This combination was then proven to provide better accuracy in classifying images from a dataset. The optimizer used is the optimizer in TensorFlow, namely Adam (*Adaptive Moment Estimation*) using learning rate and dropout values. Images of mature and immature palm oil were classified using the Xception algorithm with augmented and without augmented data. In addition, experiments were carried out by changing the parameter values of learning rate to 0.1, 0.01, 0.001 and dropout to 0.1, 0.01, 0.001. It was found that the data division was (90;10) with the best accuracy reaching 95%. Test parameters carried out by trialling were proven to increase accuracy when compared to without using parameters and flip augmentation. The best accuracy of the Xception model is 95% on augmented data with a learning rate of 0.001 and a dropout of 0.1.

Keywords: Xception; CNN; Augmentation Flip; Adam; Palm Maturity

1. PENDAHULUAN

Kelapa sawit merupakan salah satu komoditas penting di Indonesia, terlebih Indonesia merupakan negara pengekspor minyak sawit tertinggi di dunia [1]. Badan Pusat Statistik mencatat pada tahun 2022 jumlah produksi CPO di Indonesia sebanyak 46,8 juta ton. Produksi CPO dapat dipengaruhi oleh dua faktor yaitu dengan tingkat ekstraksi minyak di pabrik kelapa sawit dan kandungan minyak pada tandan buah segar sawit [2]. Buah sawit yang dikategorikan matang pada umumnya buah yang berumur 5-6 bulan setelah penyerbukan [2]. Kematangan buah sawit ditandai dengan perubahan warna pada buah dari hitam menjadi warna kuning kemerahan. Selain itu, buah sawit yang tidak matang berpengaruh negatif dan signifikan terhadap hasil produksi CPO [1].

Pemanenan buah mentah akan mempengaruhi terhadap hasil rendeman minyak yang akan dihasilkan dari buah mentah < 20% sedangkan buah matang mencapai 24%-26% [2]. Semakin matang buah sawit maka semakin banyak pula produksi CPO yang dihasilkan dari buah sawit segar begitupun sebaliknya. Kandungan tokol dan beta karoten yang terdapat pada buah kelapa sawit juga dipengaruhi oleh tingkat kematangan buah [3]. Presentase peningkatan kematangan buah sawit terhadap asam lemak pada buah meningkat 0,4 hingga 0,5% pada kondisi buah sawit matang [2]. Pada umumnya klasifikasi kematangan buah sawit dilakukan dengan mengandalkan tenaga manusia, beberapa tingkat kematangan akan sulit dibedakan dikarenakan kemiripan warna [4]. Hal ini dapat mempengaruhi hasil produksi dari buah kelapa sawit yang dihasilkannya.

Penelitian mengenai kematangan buah sawit telah dilakukan beberapa penelitian sebelumnya. Seperti penelitian dengan menggunakan ekstraksi fitur dan pemrosesan data pada ANN menunjukkan bahwa untuk seluruh hasil evaluasi, akurasi sebesar 90% [5]. Selanjutnya penelitian menggunakan SVM yang dilakukan oleh Setiawan dan Ananda didapatkan hasil sistem yang dikembangkan ini relatif lebih rendah dibandingkan dengan penelitian yang lain, akurasi data latih baru mencapai 66,67% dan 57,14% untuk data uji [6].

Pada bidang informatika penelitian kematangan buah sawit apabila kualitas dan kuantitas data yang digunakan lebih banyak maka dapat dengan menggunakan *deep learning* dalam membantu pengklasifikasian kematangan buah sawit

[6]. Beberapa penelitian sebelumnya telah dilakukan dalam upaya untuk mengetahui kematangan buah sawit segar. Pada penelitian yang dilakukan oleh Ashari dengan menggunakan CNN menunjukkan akurasi validasi data mencapai 0,92 dengan nilai loss 0,21, hasil akurasi recall sebesar 0,76 [7]. Pada penelitian Saleh dan Liansitim juga mendapatkan algoritma CNN dapat memprediksi kematangan buah sawit matang dan maupun mentah secara efektif [8].

Xception merupakan salah satu algoritma dalam Xception merupakan kepanjangan dari Extreme version of Inception[9]. Beberapa penelitian yang menggunakan Xception seperti pada klasifikasi citra tanaman minyak atsiri. Model yang digunakan performa pelatihan mencapai 93% dan validasi 77% dengan menggunakan 5 epoch [9]. Kemudian pada kasus klasifikasi Pneumotoraks menggunakan algoritma Xception [10]. Hasil performa terbaik dengan menggunakan Xception dengan memodifikasi model Xception sebesar 99,18% akurasi pelatihan.


Augmentasi data dapat meningkatkan kemampuan generalisasi jaringan dan mencegah masalah over-fitting [11]. Sehingga dalam melakukan klasifikasi gambar harus dilakukan augmentasi data untuk mencegah terjadinya over-fitting. Selain itu juga, augmentasi data juga dapat meningkatkan akurasi prediksi dalam melakukan klasifikasi gambar [12]. Pada penelitian sawit secara langsung dibandingkan menggunakan foto non-sekuensial, pra-pemrosesan akan lebih sulit. Sehingga perlu Dataset yang terdiri dari kelas-kelas gambar yang seimbang dan dataset dilakukan augmentasi untuk mendapatkan performa yang lebih baik dalam pengembangan model perlu dilakukan augmentasi data guna memperbanyak dataset [13]. Beberapa penelitian telah dilakukan pada klasifikasi gambar dengan menggunakan teknik augmentasi data. Pada penelitian klasifikasi penyakit beras dengan menggunakan *deep learning* dan augmentasi data Flip pembalikan horizontal dan vertikal [14]. Tanpa augmentasi, model CNN mencapai akurasi 56,42%, dan dengan augmentasi data, akurasi dipicu sebesar 86,59%. Augmentasi data dapat meningkatkan akurasi dalam melakukan klasifikasi gambar pada algoritma pembelajaran mendalam bekerja lebih baik dengan lebih banyak data yang digunakan [8].

Optimasi merupakan teknik dalam mengoptimalkan akurasi dalam melakukan klasifikasi untuk mencapai hasil yang ideal [15]. Pada penelitian yang menggunakan optimasi dengan menggunakan arsitektur CNN [16] Didapatkan optimasi Adam dengan menggunakan nilai dropout 0,3 memiliki hasil yang lebih baik dibandingkan dengan optimasi menggunakan SGD (Stochastic Gradient Descent). Kemudian pada penelitian membandingkan optimasi SGD, Adadelta, dan Adam pada arsitektur CNN [15]. Hasil menunjukkan optimasi Adam memiliki skor terbaik dengan akurasi 0,835, Adadelta 0,8225 dan SGD 0,6375.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Pada penelitian ini terdapat 2 proses klasifikasi dengan menggunakan data yang diaugmentasi dan data tanpa augmentasi. Proses klasifikasi dilakukan dengan menggunakan citra sawit yang terdiri dari 2 kelas yaitu sawit matang dan belum matang. Percobaan dilakukan dengan 57 skema dengan membandingkan nilai learning rate dan dropout terhadap data yang diaugmentasi dan tanpa diaugmentasi. Berikut tahapan penelitian dalam mengklasifikasi kematangan buah sawit pada **Gambar 1** dibawah ini.



Gambar 1. Tahapan penelitian klasifikasi kematangan sawit

Pada Gambar 1 menjelaskan tahapan penelitian dalam melakukan klasifikasi kematangan sawit dengan menggunakan arsitektur Xception dan hyperparameter Adam. Penelitian ini dimulai dari identifikasi masalah, pengumpulan dataset dan penerapan algoritma Xception. Kemudian didapatkan hasil dari pengujian data yang digunakan.

2.2 Pengumpulan Data

Dalam tahapan ini, penelitian menggunakan citra gambar sawit matang dan belum matang sebagai data inputan yang akan digunakan. Proses pengumpulan data dilakukan dengan mengambil langsung gambar buah sawit pada perkebunan kelapa sawit dan data yang didapatkan dari Kaggle<https://www.kaggle.com/datasets/ahmadfathan/kematangansawit>. Gambar citra sawit yang diambil langsung menggunakan kamera handphone. Foto langsung diambil dari pohonnya dan buah yang telah dipanen. Jumlah keseluruhan data yaitu 1000 gambar dengan masing masing kelas matang 500 gambar dan kelas

belum matang 500 gambar. Selain itu, terdapat data tambahan dari proses augmentasi yang dilakukan dengan augmentasi flip.

2.3 Preprocessing

Preprocessing citra menggunakan rescale dalam penelitian ini. Rescale digunakan untuk mengubah skala citra. Rescale membuat rentang nilainya menjadi 0 dan 1 yang sebelumnya nilai rentang nya antara 0 dan 255 [17]. Ukuran citra juga diubah ukurannya sesuai dengan ukuran inputan gambar dari algoritma Xception yaitu 299x299.

$$Rescale = \frac{piksel}{255} \quad (1)$$

2.4 Augmentasi

Augmentasi dilakukan untuk memperkaya data yang digunakan[18]. Data yang digunakan merupakan data citra sawit matang dan belum matang. Augmentasi dilakukan dengan augmentasi flip vertikal dan horizontal. Augmentasi dilakukan dengan otomatis pada Google Colab dengan bahasa pemrograman python dan library Augmentor. Jumlah data augmentasi yang dibuat sebanyak 500 gambar sawit matang dan 500 gambar sawit belum matang. Jadi total citra sawit yang diaugmentasi sebanyak 1000 data.

2.5 Pembagian Data


Setelah citra dilakukan augmentasi, langkah selanjutnya membagi data latih, data uji dan data validasi. Pembagian data akan dilakukan dengan skala data latih dan data uji, data validasi adalah (90:10), (80:20) dan (70:30) pada data yang di augmentasi dan tidak diaugmentasi. Data validasi diambil dari data citra sebanyak 20%.

2.6 Deep Learning

Deep learning merupakan cabang ilmu dari machine learning berbasis jaringan syaraf tiruan. Deep learning adalah algoritma permodelan tingkat tinggi pada kumpulan data yang ditransformasikan dan di tata berlapis-lapis serta mendalam. Pada[19] umumnya model deep learning dibangun berdasarkan jaringan syaraf tiruan (neuron network). Algoritma deep learning mampu dalam melakukan fitur ekstraksi secara otomatis dari kumpulan data mentah secara detail. Fitur ekstraksi berguna dalam membantu menghasilkan prediksi yang akurat dalam membedakan setiap kelas data [20]. Deep learning mampu mengklasifikasikan secara langsung dari data yang digunakan salah satunya yaitu citra gambar dan dapat meningkatkan akurasi [21]

2.7 Xception

Xception merupakan salah satu algoritma dalam deep learning yang merupakan kepanjangan dari Extreme version of Inception. Xception memiliki lapisan konvolusi yang menggabungkan konvolusi pointwise yang kemudian diikuti oleh konvolusi mendalam [10]. Kombinasi tersebut kemudian terbukti memberikan akurasi yang lebih baik dalam melakukan klasifikasi gambar suatu dataset.



Gambar 2. Layer pada algoritma Xception

Pada Gambar 2 merupakan layer yang terdapat dalam arsitektur Xception. Xception menggunakan ukuran inputan 299x299. Arsitektur lapisan Xception memiliki 36 lapisan konvolusi yang menjadi dasar jaringan ekstraksi fitur. Berikut lapisan yang terdapat pada algoritma Xception

2.8 Hyperparameter Adam

Hyperparameter merupakan tahap dengan mengkombinasikan parameter uji. Tujuannya menghasilkan akurasi yang lebih optimal dan mengurangi overfitting. Optimizer yang digunakan merupakan optimizer pada tensorflow yaitu Adam (*Adaptive Moment Estimation*). Learning rate yang digunakan 0,1 0,01 0,001, epoch 20, aktivasi menggunakan softmax dan dropout layer dengan rate 0,1 0,01 dan 0,001 pada Tabel 1.

Tabel 1. Percobaan skema yang dilakukan

Pembagian data	Learning rate	Dropout
90;10	0,1	0,1
80;20	0,01	0,01
70;30	0,001	0,001

2.9 Confusion Matrix

Pada tahapan evaluasi, penilaian dilakukan dengan confusion matrix dengan hasil akurasi, recall, presisi dan f1 score. Tahapan ini bertujuan mengukur kinerja algoritma dan augmentasi yang digunakan. Hasil evaluasi akan membandingkan data yang menggunakan augmentasi dan tidak menggunakan augmentasi pada klasifikasi kematangan buah sawit. Selain itu evaluasi akan dilakukan dengan membagi data latih dan data validasi sebesar (90:10), (80:20) dan (70:30). Berikut tabel confusion matrix klasifikasi kematangan sawit dilihat pada Tabel 2.

Tabel 2. Confusion matrix klasifikasi kematangan sawit

Kelas Benar	Sawit Matang	Belum Matang
Sawit Matang	True Positive	False Positive
Sawit Belum Matang	True Negative	False Negative

Confusion matrik menampilkan klasifikasi hasil sebagai berikut :

- True Positive (TP) adalah citra sawit yang menampilkan data negative yang diprediksi positive.
- True Negative (TN) adalah citra sawit yang menampilkan data positive yang diprediksi negative.
- False Positive (FP) adalah citra sawit yang menampilkan data negative yang diprediksi positive.
- False Negative (FN) adalah citra sawit yang menampilkan data positive yang diprediksi negative.

Confusion matrik terdiri 4 fitur matrik [22] yang terdiri dari sebagai berikut:

- Akurasi

$$Akurasi = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2)$$

- Presisi

$$Presisi = \frac{TP}{(TP+FP)} \quad (3)$$

- Recall

$$Recall = \frac{TP}{(TP+FN)} \quad (4)$$

- F1 Score

$$f1\ Score = \frac{precision \times recall}{precision+recall} \quad (5)$$

3. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Dalam tahapan ini, penelitian menggunakan citra gambar sawit matang dan belum matang sebagai data inputan yang akan digunakan. Proses pengumpulan data dilakukan dengan mengambil langsung gambar buah sawit pada perkebunan kelapa sawit dan data yang didapatkan dari Kaggle. Jumlah keseluruhan data yaitu 1000 gambar dengan masing masing kelas matang 500 gambar dan kelas belum matang 500 gambar. Selain itu, terdapat data citra sawit hasil dari augmentasi Flip vertikal dan Flip horizontal sebanyak 500 masing masing kelas dengan total 1000 citra sawit hasil augmentasi. Data terdiri data sekunder dari Kaggle dan data ambil langsung dari perkebunan perkebunan kelapa sawit di Kabupaten Siak Indragiri. Data sekunder terdiri dari 249 pada kelas sawit matang dan 363 citra sawit pada kelas tidak matang. Dari citra sawit ditambah data langsung yang diambil dari perkebunan kelapa sawit yang terdiri dari 251 data sawit matang dan 137 sawit


belum matang. Keseluruhan data dari dua kelas sawit matang dan tidak matang 1000 data citra sawit yang dapat dilihat pada Tabel 3.

Tabel 3. Citra sawit

Nama	Matang	Belum Matang
Citra Sawit (Kaggle)	249	363
Data Primary	251	137
Augmentasi	500	500
Total	1000	1000

3.2 Preprocessing

Preprocessing citra berarti suatu proses dengan memasukan atau input citra atau gambar dan menghasilkan output berupa citra gambar yang diinginkan. Preprocessing digunakan dengan menggunakan rescaling dan resize. Rescaling dilakukan untuk mengubah skala citra warna yang sebelumnya rentang warna 0-255 menjadi 0-1. Kemudian resize digunakan untuk mengubah ukuran citra kedalam ukuran inputan dari algoritma yang digunakan yaitu Xception dengan ukuran inputan citra 299x299. Berikut hasil preprocessing yang dapat dilihat pada **Gambar 3**.



Gambar 3. Hasil preprocessing rescale dan resize

3.3 Augmentasi Flip

Augmentasi dilakukan untuk memperkaya data yang digunakan menjadi lebih banyak yaitu data citra sawit. Augmentasi dilakukan dengan menambah masing masing kelas sebanyak 500 citra dengan total citra sawit hasil augmentasi sebanyak 1000 citra. Augmentasi yang digunakan adalah augmentasi Flip vertikal dan Flip horizontal. Flip adalah teknik augmentasi data dengan membalikkan citra atau gambar yang dapat dilakukan secara vertikal maupun horizontal. Misalnya pada citra buah sawit yang menghadap ke kiri dapat di balik menjadi menghadap ke arah kanan. Augmentasi menggunakan library Augmentor Pipeline pada Google Colab. Augmentasi dilakukan dengan probabilitas 100%. Kemudian data hasil Augmentasi digabungkan dalam folder pada kelas matang dan belum matang. Berikut hasil augmentasi data flip vertikal dan horizontal pada Gambar 4, Gambar 5 dan Gambar 6.



Gambar 4. Sebelum di augmentasi



Gambar 5. Augmentasi flip vertikal



Gambar 6. Augmentasi flip horizontal

3.4 Pembagian Data

Pembagian data dilakukan dengan menggunakan 3 skema percobaan. Data dibagi menjadi data latih, data uji dan data validasi. Data validasi diambil dari 20% dari total citra gambar sawit pada dua kelas sawit matang dan belum matang. Data latih dan data uji dibagi menjadi (90;10), (80;20) dan (70;30). Berikut tabel pembagian data pada Tabel 4.

Tabel 4. Pembagian data

Pembagian Data	Data Latih	Data Uji	Data Validasi
(90;10);20	720	80	200
(90;10);20 Augmentasi	1440	160	400
(80;20);20	640	160	200
(80;20);20 Augmentasi	1280	320	400
(70;30);20	560	240	200
(70;30);20 Augmentasi	1120	480	400

3.5 Implementasi Xception

Pengujian menggunakan Library Tensorflow yang ada pada Keras dengan menggunakan bahasa pemrograman Python. Pengujian dilakukan pada Google Colab dengan memanggil library Xception. Pengujian dilakukan dengan 57 Skema dengan mengubah parameter uji yaitu Learning rate dan nilai drop out. Learning rate yang digunakan 0,1 0,01 dan 0,001. Untuk dropout yang digunakan 0,1 0,01 dan 0,001. Berikut library algoritma Xception yang digunakan pada tensorflow. Pada arsitektur Xception dengan library tensorflow pada Gambar 7 terdapat langkah langkah penerapan dalam klasifikasi kematangan sawit.

```
1. from keras.applications import Xception
2. base_model=tf.keras.applications.Xception(include_top=False,
    weights="imagenet", input_tensor=Input(shape=(299,299,3)))
```

Gambar 7. Librari Xception pada tensorflow

3.6 Hyperparameter Adam

Optimasi yang digunakan dengan menggunakan optimasi Adam (*Adaptive Moment Estimation*). Optimasi dilakukan dengan menggunakan epoch 20 dalam semua skema yang ada sebanyak 57. Selain itu, optimasi dilakukan dengan mencari nilai akurasi model terbaik dengan mengubah nilai learning rate dan dropout dengan nilai 0,001, 0,01 dan 0,1 dapat dilihat pada Tabel 5. Berikut hasil percobaan parameter learning rate dan dropout dengan optimasi Adam pada algoritma Xception.

Tabel 5. Skema yang digunakan dengan mencobakan beberapa kombinasi nilai learning rate dan dropout


No	Pembagian Data	Learning rate	Dropout	Augmentasi	Tanpa Augmentasi
1	90;10	-	-	-	85,56%
2		0,001	0,001	93,75%	92,5%
3		0,001	0,01	93,75%	93,75%

4		0,001	0,1	95%	88,75%
5		0,01	0,001	93,12%	86,25%
6		0,01	0,01	91,87%	87,5%
7		0,01	0,1	93,75%	92,5%
8		0,1	0,001	86,25%	77,5%
9		0,1	0,01	84,38%	78,75%
10		0,1	0,1	85%	77,5%
11	80;20	-	-	-	87,22%
12		0,001	0,001	90,31%	90%
13		0,001	0,01	94,06%	90,62%
14		0,001	0,1	93,12%	89,38%
15		0,01	0,001	89,06%	90,62%
16		0,01	0,01	90,62%	90,62%
17		0,01	0,1	92,81%	88,75%
18		0,1	0,001	82,81%	84,38%
19		0,1	0,01	82,5%	85,62%
20		0,1	0,1	88,44%	72,5%
21	70;30	-	-	-	88,15%
22		0,001	0,001	92,29%	81,25%
23		0,001	0,01	89,38%	90,62%
24		0,001	0,1	90,62%	89,38%
25		0,01	0,001	88,33%	88,75%
26		0,01	0,01	87,5%	82,92%
27		0,01	0,1	87,08%	89,38%
28		0,1	0,001	74,17%	72,5%
29		0,1	0,01	80,62%	82,5%
30		0,1	0,1	83,75%	79,37%

Dari hasil percobaan pembagian data 90;10, 80;20 dan 70;30 diperoleh pembagian data 90;10 merupakan pembagian data terbaik dengan akurasi tertinggi 95%. Learning rate terbaik yaitu learning rate 0,001 jika dibandingkan learning rate 0,01 dan 0,1 dilihat dari akurasi yang diperoleh. Sedangkan nilai dropout terbaik 0,01 dibandingkan dropout 0,001 dan 0,1. Akurasi terendah diperoleh pada percobaan learning rate 0,1 dan dropout 0,001. Augmentasi data yang dilakukan terbukti dapat meningkatkan akurasi pada percobaan yang dilakukan dengan membandingkan data yang diaugmentasi dan tanpa diaugmentasi.


3.7 Pembahasan

Dari hasil pengujian dengan menggunakan 57 skema dengan mengubah parameter learning rate dan dropout pada algoritma Xception. Didapatkan hasil pembagian data 90;10 lebih baik dibandingkan pembagian data 80;20 dan 70;30 dilihat dari akurasi yang didapatkan. Kemudian parameter terbaik yaitu dengan menggunakan learning rate 0,001 dan dropout 0,1. Akurasi terbaik dengan augmentasi sebesar 95% dan tanpa augmentasi sebesar 93,75% pada pembagian data dan parameter uji learning rate 0,001 dropout 0,1 ditunjukkan pada Gambar 8, 9, 10 dan 11.




Gambar 8. Hasil percobaan pembagian data (90;10) learning rate 0,001 dan dropout 0,01 tanpa augmentasi

Pada Gambar 8 percobaan pembagian data 90;10 dengan learning rate 0,001 dan dropout 0,1 merupakan akurasi terbaik dari percobaan data tanpa augmentasi 93,75%. dan nilai loss 0,3175. Epoch terbaik diperoleh pada epoch ke-9 dari 20 epoch.




Gambar 9. Hasil confusion matrix pembagian data (90;10) learning rate 0,001 dan dropout 0,01 tanpa augmentasi

Pada Gambar 9 percobaan pembagian data 90;10 dengan learning rate 0,001 dan dropout 0,1 tanpa augmentasi data hasil confusion matrix diperoleh kelas yang diprediksi benar matang 32 dan diprediksi salah pada kelas matang 3. Sedangkan pada kelas belum matang diprediksi benar belum matang 43 dan diprediksi salah 2. Nilai fitur confusion matrix diperoleh akurasi 94%, presisi 93%, recal 94% dan f1-score 94%.



Gambar 10. Hasil percobaan pembagian data (90;10) learning rate 0,001 dan dropout 0,1 augmentasi

Pada Gambar 10 percobaan pembagian data 90;10 dengan learning rate 0,001 dan dropout 0,001 merupakan akurasi terbaik dengan augmentasi 95%. dan nilai loss 0,3175. Epoch terbaik diperoleh pada epoch ke-11 dari 20 epoch.



Gambar 11. Hasil confusion matrix pembagian (90;10) learning rate 0,001 dan dropout 0,01 augmentasi

Pada Gambar 11 percobaan pembagian data 90;10 dengan learning rate 0,001 dan dropout 0,01 dengan augmentasi data hasil confusion matrix diperoleh kelas yang diprediksi benar matang 82 dan diprediksi salah pada kelas matang 5. Sedangkan pada kelas belum matang diprediksi benar belum matang 70 dan diprediksi salah 3. Nilai fitur confusion matrix diperoleh akurasi 95%, presisi 95%, recal 95% dan f1-score 95%.

4. KESIMPULAN

Pendekatan deep learning menggunakan algoritma Xception pada klasifikasi kematangan sawit dengan membandingkan data yang diaugmentasi dan tanpa diaugmentasi ditambahkan dengan mengubah parameter learning rate dan dropout. Didapatkan model Xception yang ditambahkan learning rate, dropout memberikan akurasi yang lebih baik dengan augmentasi dibandingkan Xception tanpa learning rate dropout dan tanpa augmentasi. Berdasarkan hasil pengujian dengan skema pembagian data dan mengatur nilai parameter didapatkan pembagian data 90;10 terbaik dengan nilai learning rate 0,001 dan dropout 0,1. Pembagian data (90;10) akurasi terbaik mencapai 95%, pembagian data (80;20) akurasi terbaiknya 94,06% dan pembagian data (70;30) akurasi terbaiknya adalah 92,29%. Berdasarkan hasil pengujian terbukti learning rate dan dropout dapat meningkatkan akurasi jika dibandingkan dengan tanpa menggunakan parameter learning rate dan dropout. Tanpa menggunakan learning rate, dropout optimasi Adam dan augmentasi pada pembagian data didapatkan akurasi sebesar 85,56%, 87,22% dan 88,15%. Hasil percobaan parameter uji dengan nilai akurasi terendah didapatkan akurasi sebesar 72,5% pada percobaan pembagian data 70;30 dengan learning 0,1 dan dropout 0,1. Kemudian pada percobaan dengan akurasi terbaik didapatkan akurasi 95% pada percobaan pembagian data 90;10 dengan learning rate 0,001 dan dropout 0,1. Selain augmentasi, pengaturan parameter learning rate dan dropout juga berperan penting dalam meningkatkan akurasi dan mengurangi overfitting. Kombinasi kedua nya memberikan akurasi yang tinggi dengan model Xception yang dimodifikasi dengan akurasi tertinggi yaitu 95% pada data yang diberi augmentasi. Learning rate 0,001 pada 3 pembagian data merupakan parameter dengan akurasi terbaik dibandingkan learning rate 0,01 dan 0,1. Sedangkan untuk nilai dropout terbaik 0,01 dibandingkan learning rate 0,001 dan 0,1. Jadi dapat disimpulkan bahwa, algoritma Xception yang diberikan parameter uji learning rate, dropout, optimasi Adam dan Augmentasi terbukti mampu meningkatkan akurasi model Xception yang digunakan.

REFERENCES

- [1] M. Lambok, F. Sitorus, E. N. Akoeb, R. Sembiring, and M. A. Siregar, "AGRISAINS: Jurnal Ilmiah Magister Agribisnis Peningkatan Produksi Crude Palm Oil Melalui Kriteria Matang Panen Tandan Buah Segar untuk Optimalisasi Pendapatan Perusahaan Improving Crude Palm Oil Production Through Fresh Fruit Harvest Criteria for Optimization of Company Income," *Jurnal Ilmiah Magister Agribisnis*, vol. 2, no. 1, pp. 26–32, 2020, [Online].
- [2] F. Murgianto, E. Edyson, A. Ardiyanto, S. K. Putra, and L. Prabowo, "Potential Content of Palm Oil at Various Levels of Loose Fruit in Oil Palm Circle," *Jurnal Agro Industri Perkebunan*, pp. 91–98, Oct. 2021, doi: 10.25181/jaip.v9i2.2161.
- [3] I. U. P. Ranguti, "Rendemen dan Komponen Minor Minyak Sawit Mentah Berdasarkan Tingkat Kematangan Buah pada Elevasi Tinggi," *Agrotekma: Jurnal Agroteknologi dan Ilmu Pertanian*, vol. 3, no. 1, p. 9, Dec. 2018, doi: 10.31289/agr.v3i1.1933.
- [4] M. Y. M. A. Mansour, K. D. Dambul, and K. Y. Choo, "Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch," *International Journal of Technology*, vol. 13, no. 6, pp. 1326–1335, 2022, doi: 10.14716/ijtech.v13i6.5932.
- [5] A. Septiarini, A. Sunyoto, H. Hamdani, A. A. Kasim, F. Utaminigrum, and H. R. Hatta, "Machine vision for the maturity classification of oil palm fresh fruit bunches based on color and texture features," *Sci Horti*, vol. 286, Aug. 2021, doi: 10.1016/j.scienta.2021.110245.
- [6] A. W. Setiawan and A. R. Ananda, "Pengembangan Sistem Penilaian Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Citra 680 dan 750 Nm," vol. 7, no. 2, 2020, doi: 10.25126/jtiik.202072603.
- [7] S. Ashari, G. J. Yanris, and I. Purnama, "Oil Palm Fruit Ripeness Detection using Deep Learning," *Sinkron*, vol. 7, no. 2, pp. 649–656, May 2022, doi: 10.33395/sinkron.v7i2.11420.
- [8] A. Y. Saleh and E. Liansitim, "Palm oil classification using deep learning," *Science in Information Technology Letters*, vol. 1, no. 1, pp. 1–8, Apr. 2020, doi: 10.31763/sitech.v1i1.1.
- [9] J. O. Carnagie, A. R. Prabowo, E. P. Budiana, and I. K. Singgih, "Essential Oil Plants Image Classification Using Xception Model," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 395–402. doi: 10.1016/j.procs.2022.08.048.
- [10] C. Upasana, A. S. Tewari, and J. P. Singh, "An Attention-based Pneumothorax Classification using Modified Xception Model," in *Procedia Computer Science*, Elsevier B.V., 2022, pp. 74–82. doi: 10.1016/j.procs.2022.12.403.
- [11] A. Abbas, S. Jain, M. Gour, and S. Vankudothu, "Tomato plant disease detection using transfer learning with C-GAN synthetic images," *Comput Electron Agric*, vol. 187, Aug. 2021, doi: 10.1016/j.compag.2021.106279.
- [12] F. Harrou, A. Dairi, A. Dorbane, and Y. Sun, "Energy consumption prediction in water treatment plants using deep learning with data augmentation," *Results in Engineering*, vol. 20, Dec. 2023, doi: 10.1016/j.rineng.2023.101428.
- [13] Suharjito, G. N. Elwirhardja, and J. S. Prayoga, "Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches," *Comput Electron Agric*, vol. 188, Sep. 2021, doi: 10.1016/j.compag.2021.106359.
- [14] M. S. H. Talukder and A. K. Sarkar, "Nutrients deficiency diagnosis of rice crop by weighted average ensemble learning," *Smart Agricultural Technology*, vol. 4, Aug. 2023, doi: 10.1016/j.atech.2022.100155.
- [15] Irfan, Desi & Rosnelly, Rika & Wahyuni, Masri & Samudra, Jaka & Ranga, Aditia., "Perbandingan Optimasi Sgd, Adadelta, Dan Adam Dalam Klasifikasi Hydrangea Menggunakan Cnn," *JOURNAL OF SCIENCE AND SOCIAL RESEARCH*, vol. 5, p. 244, 2022. doi: 10.54314/jssr.v5i2.789.
- [16] S. Mehta, C. Paunwala and B. Vaidya, 'CNN based Traffic Sign Classification using Adam Optimizer,' 2019 International Conference on Intelligent Computing and Control Systems (ICCS), Madurai, India, 2019, pp. 1293-1298, doi: 10.1109/ICCS45141.2019.9065537.
- [17] E. N. Cahyo, E. Susanti, and R. Y. Ariyana, "Model Machine Learning Untuk Klasifikasi Kesegaran Daging Menggunakan Arsitektur Transfer Learning Xception," *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 371, Jul. 2023, doi: 10.26418/justin.v11i2.57517.
- [18] A. Mumuni and F. Mumuni, "Data augmentation: A comprehensive survey of modern approaches," *Array*, vol. 16. Elsevier B.V., Dec. 01, 2022. doi: 10.1016/j.array.2022.100258.

- [19] H. A. Pratiwi, M. Cahyanti, and M. Lamsani, "IMPLEMENTASI DEEP LEARNING FLOWER SCANNER MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK," *Sebatik*, vol. 25, no. 1, pp. 124–130, Jun. 2021, doi: 10.46984/sebatik.v25i1.1297.
- [20] F. H. Kuwil, "A new feature extraction approach of medical image based on data distribution skew," *Neuroscience Informatics*, vol. 2, no. 3, p. 100097, Sep. 2022, doi: 10.1016/j.neuri.2022.100097.
- [21] R. A. Tilasefana and R. E. Putra, "Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG NET Untuk Pengenalan Cuaca," *Journal of Informatics and Computer Science*, vol. 05, 2023.
- [22] D. Marcella and S. Devella, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-19," vol. 3, no. 1, pp. 60–70, 2022.