



Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit Menggunakan Pendekatan *Deep Learning*

Jefri Zulkarnain¹, Kusrini^{2*}, Tonny Hidayat³ 

^{1,2,3} Program Studi Teknik Informatika, Universitas Amikom Yogyakarta, Yogyakarta, Indonesia

ARTICLE INFO

Article history:

Received February 27, 2023

Accepted September 22, 2023

Available online October 25, 2023

Kata Kunci:

Klasifikasi, *Deep Learning*, Tingkat Kematangan, Tandan Buah Segar Kelapa Sawit, Parameter

Keywords:

Classification, *Deep Learning*, Maturity Rate, Oil Palm Fresh Fruit Bunches, Parameters



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

Copyright © 2023 by Author. Published by Universitas Pendidikan Ganesha.

ABSTRAK

Menilai kematangan Tandan Buah Segar (TBS) kelapa sawit sangat kompleks, kematangan TBS dilihat berdasarkan jumlah atau persentase dari buah yang terlepas dari TBS serta berdasarkan perubahan warna kulit luar TBS, dalam melakukan klasifikasi tingkat kematangan rentan terjadi kesalahan penilaian oleh manusia, kesalahan klasifikasi dapat terjadi oleh berbagai faktor. Untuk membantu kesalahan dalam klasifikasi, *Deep learning* diusulkan dalam melakukan mengklasifikasi tingkat kematangan. Tujuan dalam penelitian ini adalah menganalisis klasifikasi menggunakan *Deep learning* untuk memprediksi tingkat kematangan TBS kelapa sawit. Dalam penelitian ini diusulkan *Deep learning* dengan model ResNet50 untuk melakukan klasifikasi pada empat tingkat kematangan TBS: mentah, kurang matang, matang, dan terlalu matang. Penelitian ini akan melakukan eksperimen berdasarkan empat alokasi data, dua optimizer, dan enam learning rate serta melakukan augmentasi data. Penelitian menunjukkan eksperimen model yang diusulkan menghasilkan kondisi terbaik alokasi data 90/10, optimizer adam, dan learning rate 0.0001 dengan precision 96%, recall 98%, F1 score 97%, dan accuracy 97%. Kesimpulan dari hasil penelitian model yang diusulkan berhasil mencapai akurasi 97%, namun demikian dalam melakukan klasifikasi tingkat kematangan membutuhkan data latih dengan ukuran besar untuk mendapatkan hasil klasifikasi yang baik serta memperhatikan dataset dan metode yang digunakan.

ABSTRACT

In assessing the maturity of Fresh Fruit Bunches (FFB) coconut palm is very complex, FFB maturity is seen based on the amount or percentage of the fruit that is independent of TBS as well as based on changes in the color of the outer skin FFB, in carrying out the classification of the level of maturity vulnerable to human error of assessment, error of classification can occur by various factors. To help errors in classification, Deep learning is proposed in conducting classification of maturity levels. The aim of this study is to conduct a classification using Deep learning to predict the maturity rate of palm coconut FFB. The study proposed Deep learning with the ResNet50 model to classify FFB at four levels of maturity: raw, less mature, mature, and over-mature. The research will conduct experiments based on four data allocations, two optimizers, and six learning rates and perform data augmentations. The research showed that the proposed model experiments produced the best conditions of data allocation 90/10, optimizer adam, and learning rate 0.0001 with accuracy 96%, recall 98%, F1 score 97%, and accurate 97%. The conclusion of the research results of the proposed model has achieved accuracy of 97%, but in conducting the classification of the level of maturity requires large-scale training data to obtain good calcification results as well as pay attention to the datasets and methods used.

1. PENDAHULUAN

Indonesia merupakan salah satu penghasil minyak sawit terbesar setelah Malaysia dan Thailand (Prasetyo et al., 2020). Tanaman kelapa sawit merupakan salah satu komoditas pangan utama dunia dan menjadi harapan perekonomian (Hardi et al., 2020; Prakosa et al., 2023). Tanaman kelapa sawit menjadi salah satu tanaman perkebunan terpenting karena mampu menghasilkan minyak nabati, produk sehari-hari yang dihasilkan oleh minyak nabati tanaman kelapa sawit adalah produk edible dan produk non edible (Himmah et al., 2020; Septiarini et al., 2021). Berdasarkan data food agriculture organization (FAO), pada tahun 2050 permintaan akan produksi minyak sawit akan mencapai 156 juta ton (Himmah et al., 2020; Lye Chew et al., 2021). Angka produksi dan permintaan akan minyak sawit ini menjadikan sawit komoditas pangan internasional yang sangat unggul, maka atas dasar hal itu untuk memproduksi sawit dengan kualitas yang baik adalah dengan memanen Tandan Buah Segar (TBS) kelapa sawit pada pemasakan yang optimal (Raj et al., 2021).

*Corresponding author.

E-mail addresses: kusrini@amikom.ac.id (Kusrini)

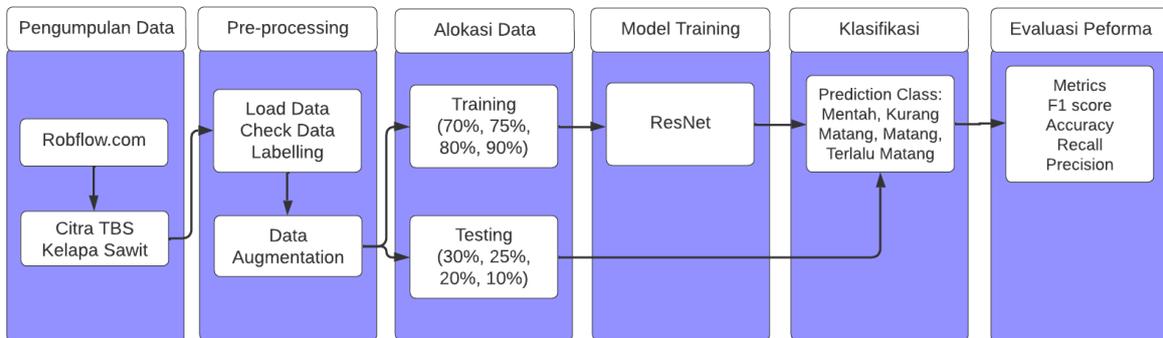
Kelapa sawit menghasilkan tandan buah segar yang akan diolah menjadi minyak nabati, untuk mendapatkan minyak nabati dengan kualitas tinggi. Tingkat kematangan TBS yang dihasilkan harus berkualitas tinggi, untuk menilai kualitas TBS dapat ditentukan berdasarkan tekstur, bentuk dan ciri warna dari buah TBS (Dermawan & Ashari, 2018; Septiarini et al., 2021). Minyak dengan kualitas tinggi dan memiliki nilai komoditas yang tinggi hanya dihasilkan oleh TBS yang telah matang kemudian diikuti oleh TBS yang terlalu matang, sedangkan minyak dengan kualitas rendah dihasilkan dari tandan mentah dan kurang matang yang dipanen tanpa kontrol kematangan (Junkwon et al., 2009; Mansour et al., 2022). Mengontrol kematangan TBS sangat kompleks, dengan menilai tingkat kematangan TBS berdasarkan jumlah atau persentase dari buah yang terlepas dari tandan buah segar kelapa sawit serta berdasarkan perubahan warna kulit luar TBS kelapa sawit. Perubahan warna menjadi penilaian utama tingkat kematangan buah kelapa sawit hal ini rentan terjadi kesalahan penilaian oleh manusia, dikarenakan persepsi manusia terhadap warna dapat berubah-ubah dipengaruhi oleh kondisi fisik dan psikologis manusia (Being et al., 2020). Buah yang terlepas dari TBS kelapa sawit dapat terjadi oleh faktor lain yang membuat buah cepat berguguran, salah satu penyebabnya adalah TBS tidak dipanen pada saat optimal (Alfatni et al., 2022; Ashari et al., 2022). Metode konvensional memerlukan waktu yang cukup lama dan membutuhkan banyak tenaga kerja dalam pelaksanaannya (Sinambela et al., 2020). Oleh karena itu, perlu adanya pengembangan klasifikasi tingkat kematangan TBS pada proses pemanenan dan pembelian untuk mengoptimalkan kualitas minyak yang akan dihasilkan dari TBS. Dua pendekatan yang paling sering digunakan dalam melakukan klasifikasi tingkat kematangan TBS kelapa sawit yaitu *machine learning* dan *deep learning*.

Deep learning adalah proses pembelajaran dengan menggunakan algoritma yang mengacu pada hukum matematika dimana *Deep learning* bekerja mirip dengan sistem otak manusia (Fitra Maulana & Rochmawati, 2019). *Deep learning* telah menunjukkan hasil yang cukup menjanjikan dalam melakukan klasifikasi citra pada kasus yang kompleks (Herman et al., 2020). Dalam literatur, beberapa penulis telah meneliti penggunaan alat dan teknik algoritma pada klasifikasi tingkat kematangan. Seperti melakukan klasifikasi tingkat kematangan tandan buah segars menggunakan algoritma Convolutional Neural Network (CNN) (Ashari et al., 2022; Prasetyo et al., 2020; Saleh & Liansitim, 2020; Yuen Teh et al., 2021). Regresi, AlexNet, K-Means Clustering, YOLOv4 dan algoritma juga diterapkan untuk mengklasifikasi tingkat kematangan pada pisang menggunakan CNN dan k-nearest neighbor (KNN) pada buah pepaya (Albakri et al., 2019; Behera et al., 2021; Himmah et al., 2020; Lai et al., 2022; Saranya et al., 2022; Wong et al., 2020). Dalam melakukan klasifikasi, selain algoritma juga dipengaruhi oleh jumlah data, hyperparameter, dan teknik akuisisi data. Model *deep learning* akan bekerja dengan baik pada data yang besar untuk mendapatkan akurasi yang tinggi dan menghindari *overfitting*, hal ini merupakan kelemahan yang ada pada *deep learning*. *Transfer learning* digunakan untuk mengatasi hal tersebut, yang telah terbukti pada CNN yang memiliki dataset kecil (Suharjito et al., 2021). Selain itu teknik lain yang digunakan untuk mengatasi *overfitting* data adalah augmentasi data. Augmentasi data merupakan salah satu teknik untuk menambah data dalam data set dengan berbagai teknik, yaitu dengan cara menggeser, membalik, memutar, mencerahkan, memperbesar dan memperkecil gambar (Perez & Wang, 2017).

Hasil *deep learning* juga dipengaruhi oleh Hyperparameter yang digunakan pada sebuah model *deep learning*, salah satunya *learning rate* dan *batch size*. *Learning rate* sendiri adalah parameter pada proses training yang berfungsi untuk menghitung nilai koreksi bobot waktu training data. *Batch size* adalah jumlah contoh data yang digunakan dalam satu iterasi training data (Rochmawati et al., 2021). Perbedaan jumlah parameter yang digunakan mempengaruhi hasil evaluasi terhadap model yang dikembangkan (Rifqi, 2021). Kurangnya informasi tentang parameter penting menjadi alasan terbatasnya kinerja model yang diusulkan. Ketika parameter pengikatan spesifik lokasi diukur dan disertakan, model yang diusulkan lebih akurat (Khan et al., 2021). Berdasarkan penelitian sebelumnya, tidak hanya augmentasi data yang mempengaruhi hasil prediksi tetapi juga skenario yang digunakan dan hyperparameter yang akan digunakan selama proses klasifikasi. Kontribusi utama dari pekerjaan yang akan disajikan dalam penelitian ini adalah bagaimana penerapan hyperparameter dapat meningkatkan metode untuk mengklasifikasi tingkat kematangan tandan buah segar kelapa sawit. Penelitian ini untuk mengklasifikasi tingkat kematangan TBS kelapa sawit dengan empat tingkat kematangan yaitu mentah, kurang matang, matang, dan terlalu matang memanfaatkan metode *deep learning* convolutional neural networks (CNN) dengan arsitektur ResNet50. Penelitian ini diharapkan dapat membantu mengembangkan model dalam mengklasifikasi tingkat kematangan TBS serta mengoptimalkan kualitas minyak dari hasil pengolahan TBS kelapa sawit.

2. METODE

Penelitian ini menggunakan jenis penelitian eksperimental, pada hal ini dilakukan berbagai tindakan dimulai dari pengumpulan data, *pre-processing* data, alokasi data, kemudian dilakukan pemodelan data, selanjutnya testing serta evaluasi. Tahapan pada penelitian ini digambarkan pada Gambar 1.



Gambar 1. Alur Tahapan Penelitian

Proses awal dilakukan pengumpulan dataset yang akan digunakan pada penelitian, dataset yang dikumpulkan berasal dari web penyedia dataset computer vision yaitu <https://roboflow.com>. Data citra yang dikumpulkan merupakan data citra TBS kelapa sawit yang terdiri dari buah mentah, kurang matang, matang, dan terlalu matang dengan berbagai latar belakang (Ginanjar, 2022b, 2022a; New-workspace-Ovwie, 2021). Data citra TBS kelapa sawit yang akan digunakan pada penelitian ini sejumlah 4.938 data. Sebaran data pada dataset yang dikumpulkan terdiri dari mentah berjumlah 331 data, kurang matang berjumlah 1548, matang berjumlah 2236 data, dan yang terakhir terlalu matang 723 data. Tingkat kematangan TBS kelapa sawit disajikan pada Tabel 1.

Tabel 1. Tingkat Kematangan TBS Kelapa Sawit

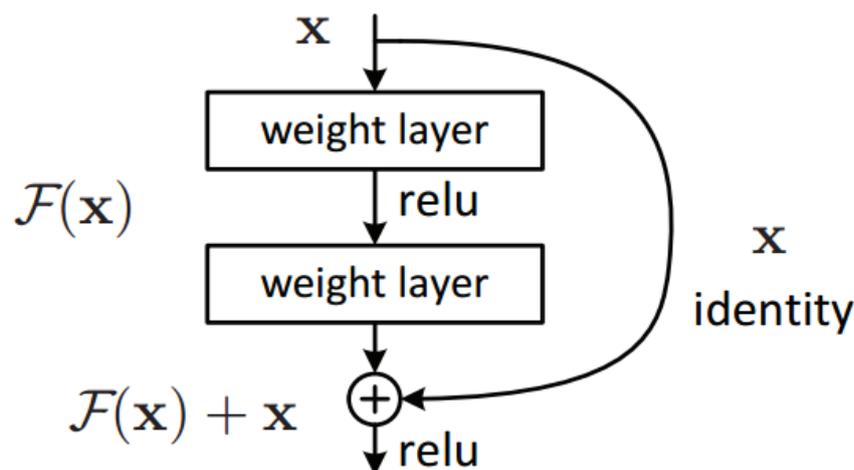
Citra TBS Kelapa Sawit	Kelas	Keterangan
	Kurang Matang	Buah sudah berubah warna menjadi hitam kemerahan dan sudah ada buah yang terlepas satu sampai sembilan buah yang terlepas.
	Matang	Buah pada tandan sudah mulai berubah menjadi jingga kemerahan dan 10 buah yang terlepas.
	Terlalu Matang	Buah pada tandan memiliki warna jingga kemerahan dan lebih dari 50 buah terlepas.
	Mentah	Buah pada tandan masih keras, berwarna hitam dan belum ada yang terlepas.

Pre-processing pada Neural Network persiapan data merupakan salah satu tahapan penting, karena persiapan terhadap data dapat meningkatkan kualitas analisis, mempercepat proses pelatihan, mengurangi kesalahan pemodelan. Tahapan *pre-processing* data merupakan tahapan mengubah data mentah menjadi satu format data yang umum (Koval, 2018). Tahapan dimulai dari load data. Untuk memastikan bahwa data sesuai dengan yang telah dikumpulkan sebelumnya, dilanjutkan dengan pengecekan data, disini pengecekan format data dilakukan dengan melakukan data check. Setelah selesai melakukan pengecekan data, maka dilakukan penyamaan ukuran data atau *resizing* citra pada proses augmentasi data. Augmentasi data yang dilakukan tidak hanya melakukan perubahan ukuran data, pada penelitian ini juga dilakukan pembalikan, pemotongan, dan pemutaran pada citra. Adapun range yang digunakan pada proses augmentasi data dapat dilihat pada Tabel 2.

Tabel 2. Augmentasi Data yang diterapkan pada Dataset

Augmentasi Data	Range
Resize	150
Center crop	150
Random Horizontal Flip	10
Random Rotation	10

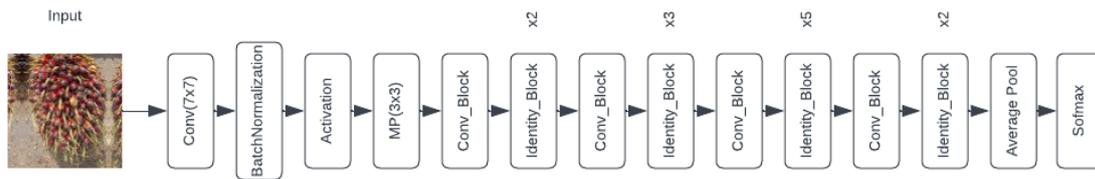
Data yang akan digunakan pada proses modeling dan klasifikasi adalah data training dan data testing, data training adalah sekumpulan data yang digunakan untuk melatih model sedangkan data testing adalah sekumpulan data yang digunakan untuk melakukan pengujian pada model yang telah didapatkan (Ashari et al., 2022). Data yang akan dialokasikan pada penelitian ini menjadi data training dan testing dengan empat skenario data yaitu 70:30, 75:25, 80:20, dan 90:10. *Modeling* dan testing, resNet50 sebagai arsitektur dari convolutional neural network akan digunakan sebagai metode pada penelitian ini. ResNet atau residual network digunakan karena memiliki ciri khusus yaitu *skip connections*, *batch normalization*, dan menghilangkan *fully connected layers* yang berhasil menyelesaikan masalah yang ada pada arsitektur sebelumnya yaitu keadaan jika jaringan yang ada terlalu dalam mengakibatkan penurunan akurasi dan tingginya error yang dihasilkan. Dengan cara melompati atau melewati beberapa layer ResNet berhasil menyelesaikan masalah yang ada sebelumnya *vanishing gradient problem*, dan cara penyelesaian dikenal dengan *residual learning* yang divisualisasikan pada Gambar 2. ResNet dengan kemampuan tersebut menjadi standar dalam penggunaan secara praktis dan menjadi Arsitektur terbaik sejak 2016, yang dibangun oleh Kaiming pada tahun 2015 (Suyanto et al., 2019).



Gambar 2. Residual Learning Block

Pada penelitian ini akan dilakukan tahapan modeling, tahapan ini bertujuan untuk mendapatkan model dari proses training data menggunakan arsitektur dari convolutional neural networks yaitu ResNet50 dengan menggunakan parameter, optimizer dan alokasi data yang berbeda pada proses training citra TBS, proses training citra TBS akan dilakukan sebanyak 2 skenario. Keseluruhan arsitektur ResNet50 tersusun atas 5 proses tahapan konvolusi, kemudian dilanjutkan dengan average pooling, dan berakhir pada fully connected layer yang berfungsi sebagai layer prediksi (Oktafanda, 2022), pada penelitian yang akan dilakukan akan menggunakan 1 maxpool dan 1 average pool layer, yang divisualisasikan pada Gambar

3. Karena keluaran kami hanya memiliki empat kelas kami mengganti fully connected dari 1000 kelas menjadi 4 kelas sesuai dengan kelas yang ada pada dataset pada penelitian ini dan tetap mempertahankan bobot yang ada pada ResNet50.



Gambar 3. Proses ResNet50

Dari proses training akan menghasilkan sebuah model, model inilah yang akan digunakan untuk pengujian dalam klasifikasi tingkat kematangan TBS menggunakan data test yaitu data yang berbeda pada proses pelatihan model. Pengujian terhadap model dilakukan untuk mengevaluasi hasil dari ResNet50. Tahapan selanjutnya pada alur penelitian ini adalah evaluasi. Evaluasi dilakukan untuk menarik hasil klasifikasi dan kesimpulan dari hasil pengujian model. Model evaluasi yang akan digunakan untuk proses evaluasi adalah confusion matrix, untuk mendapatkan model terbaik dari model yang telah dilatih dan dilakukan testing. Evaluasi yang dilakukan terhadap sebuah model klasifikasi dilakukan dengan menghitung suatu ukuran pada kumpulan data uji yang tidak digunakan dalam pelatihan model klasifikasi. Ada beberapa ukuran yang digunakan untuk mengevaluasi model klasifikasi yaitu accuracy, error rate, recall, specificity, precision, dan F1, F-Measure atau F-score (Suyanto, 2017). Ukuran yang akan digunakan pada penelitian ini adalah accuracy, recall, precision, dan F1, F-Measure atau F-score. Accuracy merupakan rasio dari jumlah hasil prediksi yang benar dan jumlah total data prediksi. Recall berupa ukuran kelengkapan, dimana kelas positif yang diprediksi sebagai kelas positif. Precision merupakan ukuran kepastian, kelas positif yang diprediksi benar sebagai kelas positif. F-Score dapat dikatakan sebagai rata-rata bobot dari nilai recall dan precision, nilai F-score idealnya berada pada angka 1 dan angka 0 menjadi nilai terburuk.

3. HASIL DAN PEMBAHASAN

Hasil

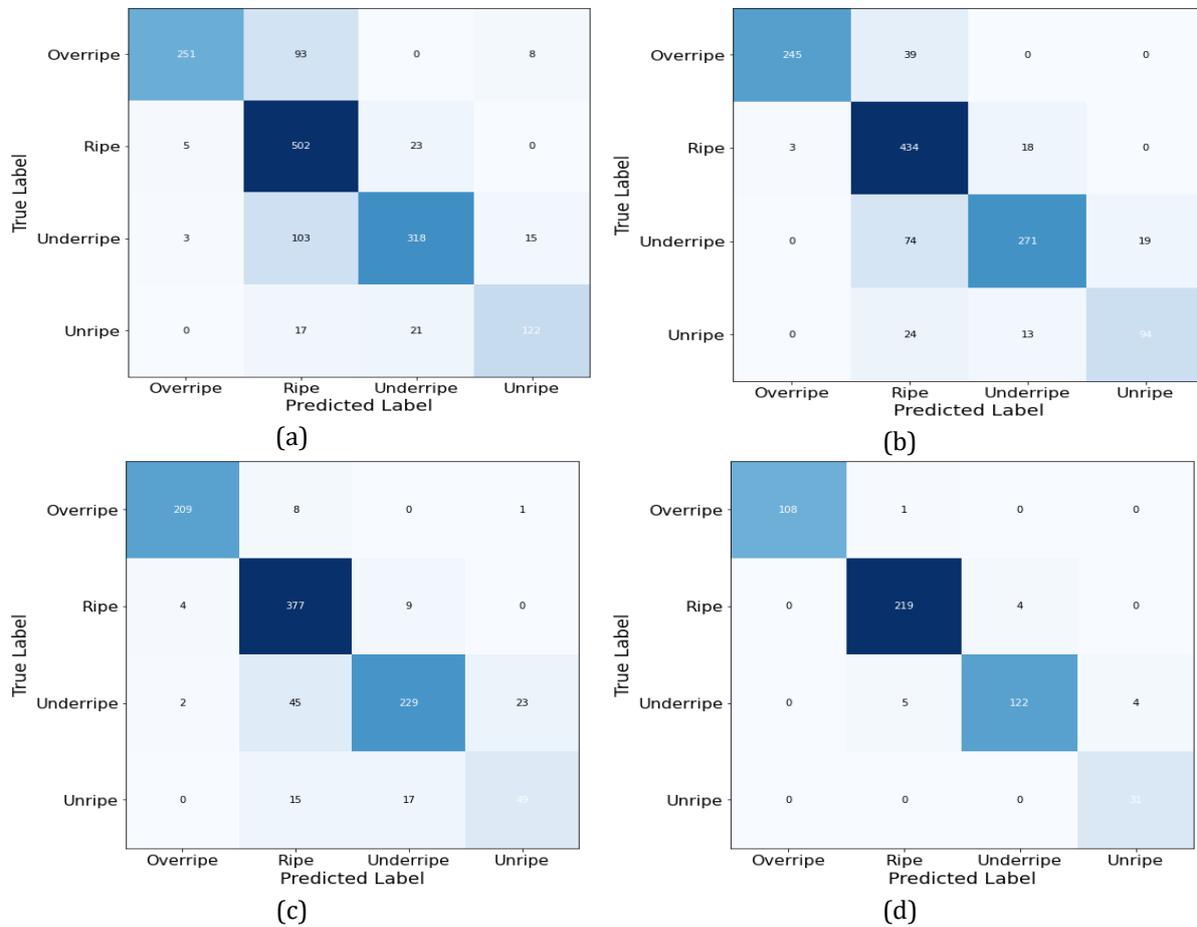
Dalam penelitian ini, dilakukan pengujian kinerja model klasifikasi dalam melakukan klasifikasi pada tingkat kematangan TBS kelapa sawit yang dilakukan dalam dua skenario. Studi eksperimental dilaksanakan menggunakan Google Collaboratory dengan GPU Nvidia T4 dan menggunakan bahasa pemrograman python dijalankan pada laptop asus dengan I5 8th gen. Skenario pertama dilakukan dengan melakukan input 100 epoch, 32 batch size, adam optimizer, dan dengan variasi learning rate 0.0001, 0.00035, 0.0005, 0.00075, dan 0.0009. Alokasi data yang akan digunakan pada skenario ini adalah 70/30, 75/25, 80/20, dan 90/10. Kinerja model diukur dari segi akurasi dan loss yang dihasilkan, hasil kinerja model divisualisasikan pada Tabel 3.

Tabel 3. Perbandingan Kinerja Pelatihan Model Optimizer Adam

Data Alokasi	Learning Rate	Train Accuracy	Train Loss	Val Accuracy	Val Loss
70/30	0.00035	0.9987	0.0056	0.9896	0.0500
75/25	0.0001	0.9979	0.0083	0.9758	0.0867
80/20	0.00035	0.9944	0.0201	0.9591	0.0995
90/10	0.0001	0.9965	0.0106	0.9795	0.0731

Tabel 3 menyajikan hasil dari training model menggunakan optimizer adam dengan melihat kondisi terbaik dari masing-masing alokasi data. Dapat dilihat bahwa data alokasi 70/30 dengan learning rate 0.00035 merupakan model dengan train accuracy dan val accuracy tertinggi serta train dan loss terendah. Walaupun begitu angka selisih antara train accuracy, val accuracy, train loss, dan val loss model pada jumlah data yang digunakan relatif kecil. Selanjutnya model yang telah didapatkan, dilakukan pengujian menggunakan data testing. Disini kami memvisualisasikan confusion matrix pada Gambar 4 untuk menunjukkan kinerja dari masing-masing model yang sebelumnya telah didapatkan, hasil accuracy, precision, recall dan f1 score divisualisasikan pada Tabel 4. Dapat dilihat bahwa alokasi data 90/10 memiliki nilai terbaik pada evaluasi pengujian dengan precision 96%, recall 98%, F1 score 97%, dan accuracy 97%. Hasil ini berbanding terbalik dengan hasil pada pelatihan model, dimana alokasi data 70/30

mendapati hasil pengujian akurasi yang terendah dari keempat model yang ada. Pengaruh jumlah data latih mempengaruhi hasil pengujian pada penelitian ini, dapat dilihat bahwa semakin banyak data latih yang digunakan, akurasi yang dihasilkan juga meningkat.



Gambar 4. Confusion Matrix Adam Hasil Klasifikasi (terlalu Matang, Matang, Kurang Matang, Mentah), (a) Alokasi Data 70/30, (b) Alokasi Data 75/25, (c) Alokasi Data 80/20, dan (d) Alokasi Data 90/10

Tabel 4. Hasil Kinerja Pengujian Model Adam

Data Alokasi	Precision (%)	Recall (%)	F1 (%)	Accuracy (%)
70/30	85	79	81	81
75/25	86	82	84	85
80/20	85	82	83	87
90/10	96	98	97	97

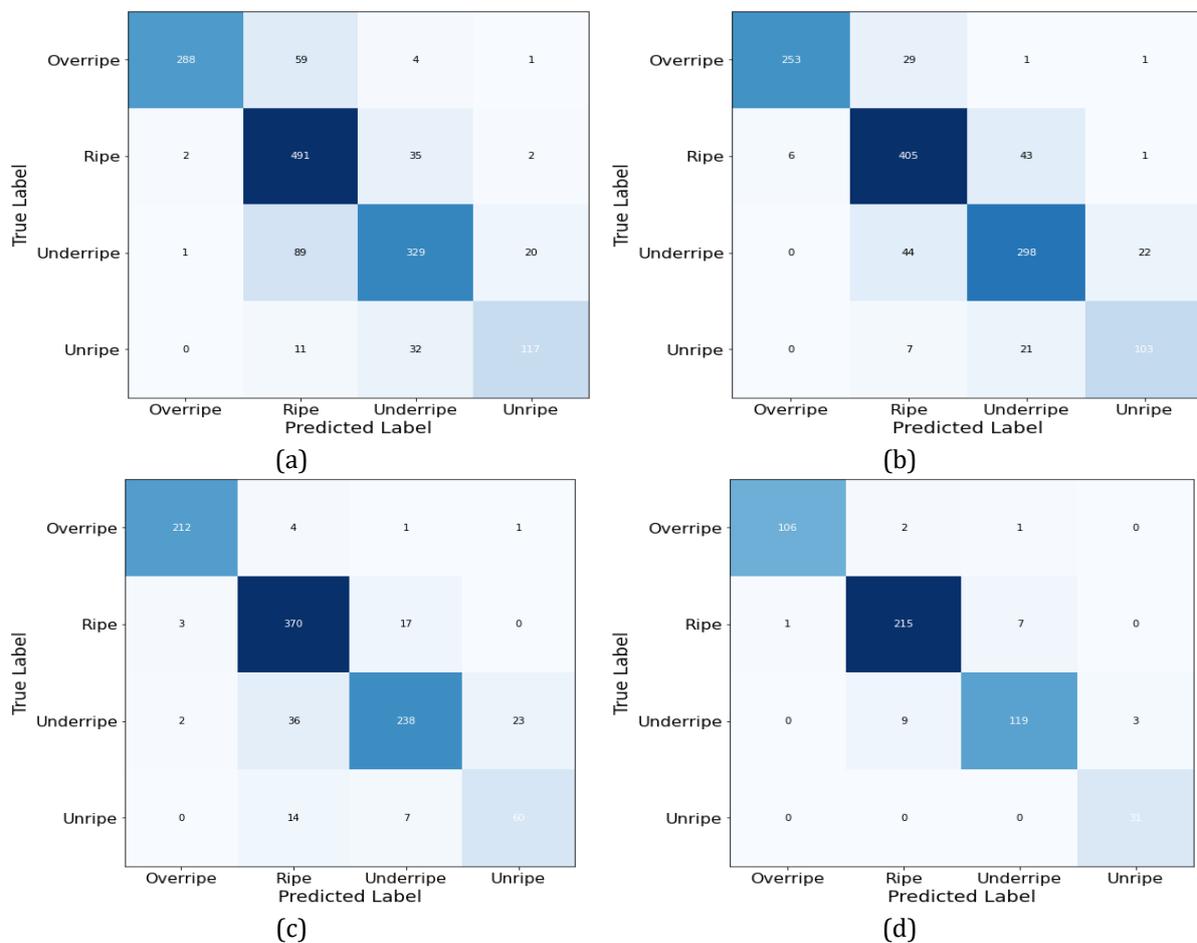
Skenario kedua akan dilakukan input parameter seperti pada skenario pertama, yang membedakan pada skenario kedua adalah optimizer yang akan digunakan pada skenario kedua akan menggunakan optimizer SGD. Hasil kinerja pelatihan model menggunakan optimizer SGD divisualisasikan pada Tabel 5, dapat disimpulkan bahwa model dengan train accuracy dan train loss terbaik adalah model dengan alokasi data 80/20 dengan learning rate 0.0009, sedangkan model dengan val accuracy tertinggi dan val loss terendah ada pada model 70/30 dengan learning rate 0.0009. Sama seperti skenario sebelumnya pada skenario ini juga dilakukan pengujian pada model yang telah didapatkan dengan data testing dan dievaluasi menggunakan confusion matrix. Hasil yang didapatkan pada skenario ini memiliki pola yang sama pada skenario pertama, dimana model dengan accuracy pelatihan dan validasi terbaik menjadi hasil pengujian terendah dibanding model lainnya seperti yang divisualisasikan pada Tabel 6, dan Gambar 5. Dimana model dengan hasil precision, recall, F1 score, dan accuracy terbaik pada alokasi data 90/10 dengan hasil 95%, 96%, 95%, dan 95%. Pada skenario ini akurasi pengujian juga meningkat seiring dengan jumlah data pelatihan seperti pada skenario pertama. Pada penelitian ini juga dilakukan komparasi terhadap Learning rate yang akan dibahas pada sub bab berikutnya.

Tabel 5. Perbandingan Kinerja Pelatihan Model *Optimizer* SGD

Data Alokasi	Learning Rate	Train Accuracy	Train Loss	Val Accuracy	Val Loss
70/30	0.0009	0.9984	0.0123	0.9780	0.0706
75/25	0.0009	0.9949	0.0204	0.9621	0.1208
80/20	0.0009	0.9989	0.0101	0.9777	0.0953
90/10	0.0009	0.9983	0.0095	0.9687	0.0791

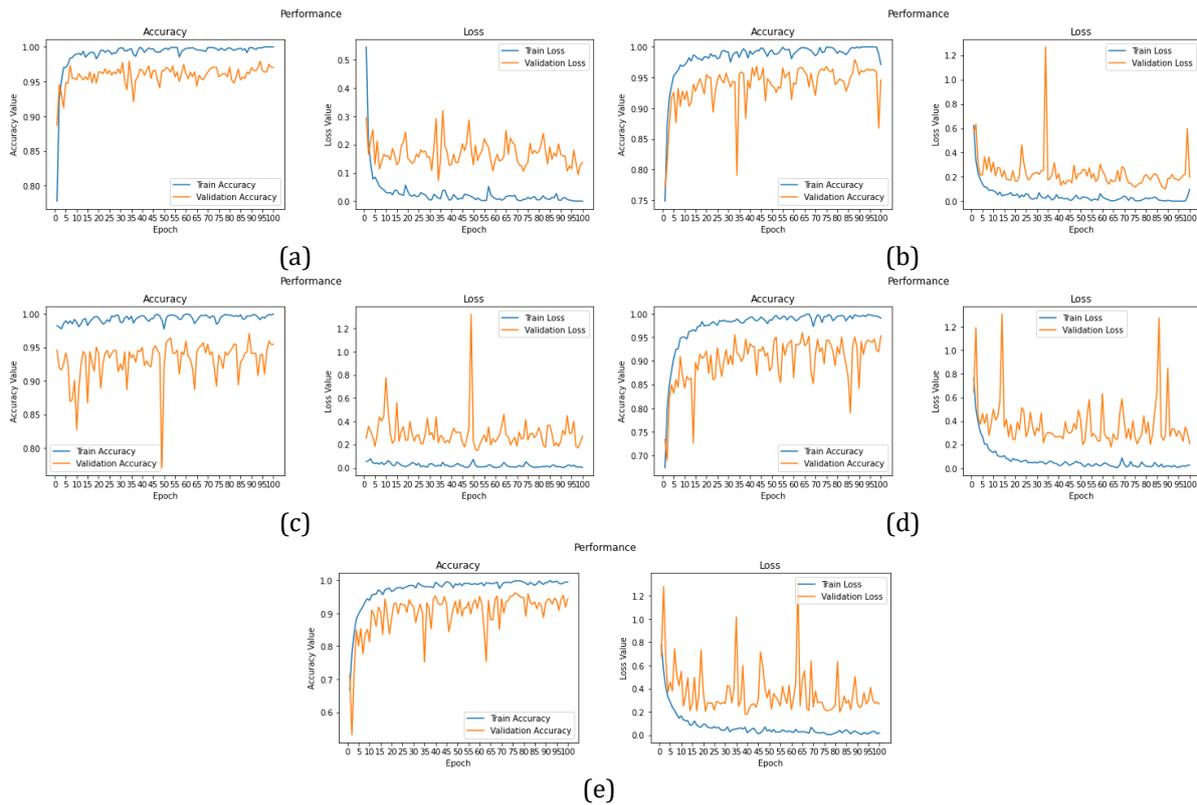
Tabel 6. Hasil Kinerja Pengujian Model SGD

Data Alokasi	Precision (%)	Recall (%)	F1 (%)	Accuracy (%)
70/30	85	81	82	83
75/25	86	85	85	86
80/20	87	86	86	89
90/10	95	96	95	95



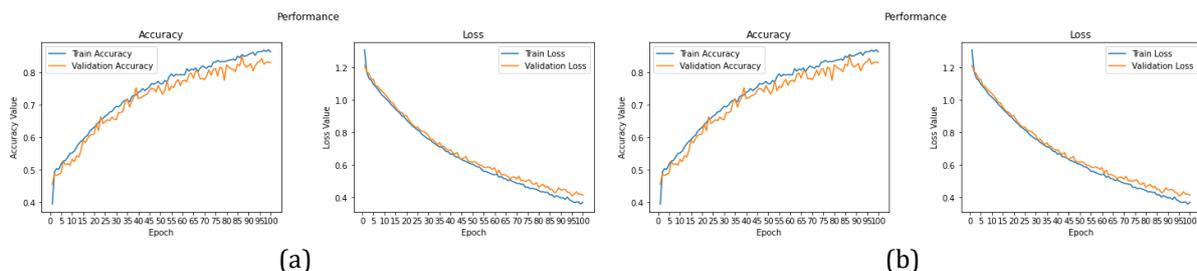
Gambar 5. Confusion matrix SGD hasil klasifikasi (terlalu matang, matang, kurang matang, mentah), (a) alokasi data 70/30, (b) alokasi data 75/25, (c) alokasi data 80/20, dan (d) alokasi data 90/10

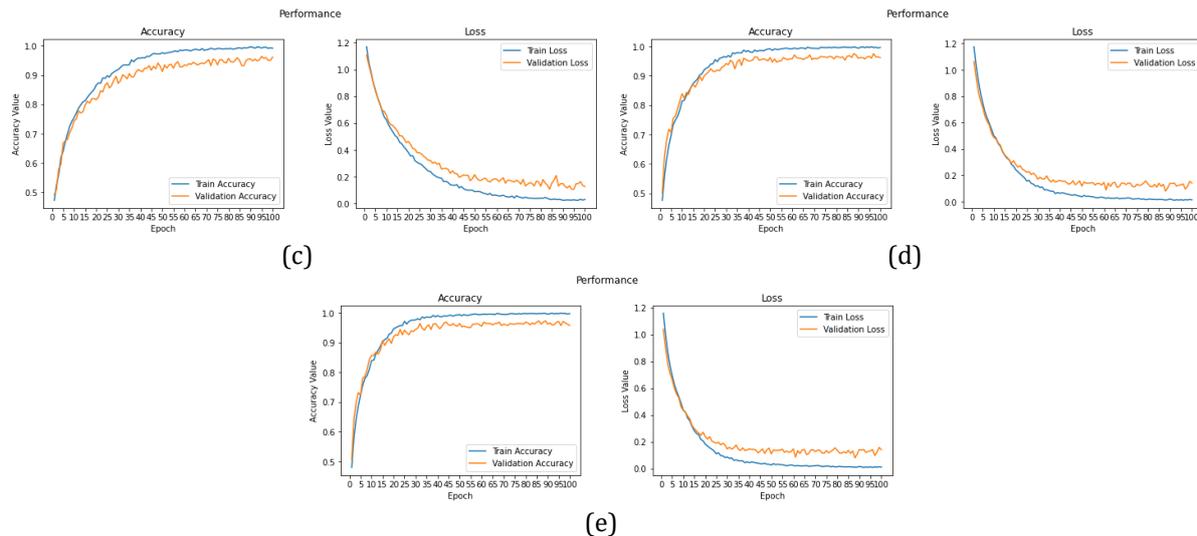
Perbandingan Learning rate pertama dilakukan dengan menggunakan learning rate 0.0001, 0.00035, 0.0005, 0.00075, dan 0.0009. Dengan parameter yang akan digunakan optimizer adam, 100 epoch, 32 batch size, alokasi data 90/10. Hasilnya bisa dilihat pada [Gambar 6](#).



Gambar 6. Komparasi LR Adam (a) 0.0001, (b)0.00035 , (c) 0.0005, (d) 0.00075, dan 0.0009

Berdasarkan **Gambar 6** bahwa hasil learning rate 0.00035, 0.0005, 0.00075, dan 0.0009 akurasi yang dihasilkan berada di angka yang cukup tinggi, namun untuk akurasi validasi mengalami ketidakstabilan dengan mengalami naik turun hingga menyentuh angka di bawah 0.8. Hal ini juga terjadi pada kurva loss pada keempat learning rate yang sebelumnya disebut mengalami ketidakstabilan dan angka kurva loss sempat berada diatas angka 1, dimana loss yang dihasilkan sangat tinggi. Untuk hasil learning rate dengan hasil paling bagus adalah 0.0001. Hal ini karena train dan val akurasi yang dihasilkan lebih stabil dan angka validasi terendah berada pada titik 0.89. Sejalan dengan train dan val kaurasi, loss yang dihasilkan lebih stabil dan pada angka yang rendah yaitu dibawah 0.3. Jadi dapat disimpulkan hasil yang paling optimal diantara kelima learning rate adalah learning rate 0,0001. Perbandingan *Learning rate* yang kedua dilakukan dengan menggunakan learning rate 0.0001, 0.00035, 0.0005, 0.00075, dan 0.0009. Dengan parameter yang akan digunakan optimizer SGD, 100 epoch, 32 batch size, alokasi data 90/10. Hasilnya bisa dilihat pada **Gambar 7**. Dapat dilihat pada percobaan ini learning rate 0.0001 merupakan *learning rate* dengan akurasi paling rendah dan loss yang dihasilkan masih tergolong tinggi walaupun mengalami penurunan kestabilan loss tetapi masih berada lebih besar daripada learning rate yang lain. Sedangkan *Learning rate* 0.00035 dan 0.0005 menghasilkan akurasi yang hampir menyentuh angka 1, akan tetapi untuk kestabilan train dan val akurasi mulai terjadi di angka epoch 50, begitu juga yang terjadi pada loss yang dihasilkan. Learning rate dengan hasil terbaik pada percobaan ini adalah pada 0.00075 dan 0.0009, karena train dan val yang dihasilkan menyentuh angka 1 beserta mengalami kestabilan lebih cepat daripada *learning rate* yang lain yaitu pada epoch 25. Jadi hasil yang paling optimal diantara kelima angka learning rate pada percobaan kedua yang dibandingkan adalah 0.00075 dan 0.0009.





Gambar 7. Komparasi LR SGD (a) 0.0001, (b)0.00035 , (c) 0.0005, (d) 0.00075, dan 0.0009

Pembahasan

Tingkat kematangan tandan buah segar kelapa sawit menjadi penentu dalam menghasilkan minyak nabati kelapa sawit, karena minyak nabati kelapa sawit berkualitas tinggi dihasilkan oleh sawit yang telah matang dan terlalu matang, karena hal itulah dibutuhkan kontrol terhadap tingkat kematangan TBS kelapa sawit (Junkwon et al., 2009). Pada penelitian ini diusulkan metode klasifikasi tingkat kematangan TBS kelapa sawit dengan menggunakan ResNet50 dengan melakukan eksperimen pada parameter yang berbeda yaitu pada optimizer adam dan SGD serta pada learning rate 0,0001, 0,00035, 0,0005, 0,00075, dan 0,0009. Hasil dari penelitian ini berhasil mengklasifikasi empat tingkat kematangan TBS kelapa sawit (mentah, kurang matang, matang, dan terlalu matang), dengan masing-masing skenario eksperimen menghasilkan kondisi terbaik. Kinerja tersebut berdasarkan dataset yang kami gunakan, ada kemungkinan hasil yang kami temukan dapat berbeda pada dataset lain. Kinerja model dalam eksperimen yang telah dilakukan ini mampu bersaing. Metode Convolutional Neural Network (CNN) dua kelas data untuk klasifikasi kematangan TBS menghasilkan akurasi 96% (Saleh & Liansitim, 2020). Pada penelitian lain menggunakan metode yang sama untuk melakukan klasifikasi tingkat kematangan TBS dengan memadukan fitur deteksi tepi berwarna dengan hasil akurasi 91,5% (Yuen Teh et al., 2021). Klasifikasi TBS kelapa sawit menggunakan *deep learning*. Menggunakan CNN dengan teknik augmentasi data pada tiga tingkat kematangan tbs dengan hasil 98% pada proses pelatihan dan 76% pada proses pengujian model (Ashari et al., 2022; Wang et al., 2021).

Temuan pada penelitian ini *learning rate* pada optimizer adam, semakin meningkat learning rate akurasi yang dihasilkan terus mengalami ketidakstabilan, sedangkan pada learning rate dengan optimizer SGD memiliki hasil yang berbeda dimana semakin tinggi angka learning rate justru semakin stabil dalam proses pembelajaran dibandingkan pada optimizer adam. Jika nilai learning rate terlalu kecil, pelatihan akan memakan waktu terlalu lama, namun jika terlalu besar, pembelajar akan terlalu cepat dan proses pelatihan tidak stabil (Rochmawati et al., 2021). Dalam proses klasifikasi tingkat kematangan tandan buah segar kelapa sawit, terjadi kesalahan klasifikasi antara satu tingkat kematangan dengan tingkat kematangan yang lain hal ini terjadi karena kesalahan dalam melakukan klasifikasi antara tingkat kematangan kurang matang, matang, dan terlalu matang pada penelitian ini karena memiliki kesamaan ruang warna dan kualitas dari dataset. Kesalahan klasifikasi TBS karena perubahan warna buah yang tidak merata (Septiarini et al., 2021). Kesalahan-kesalahan dalam klasifikasi juga dapat disebabkan tingginya tingkat okulasi dan objek yang menutupi TBS (Behera et al., 2021; Prasetyo et al., 2020). Akurasi yang dihasilkan dalam penelitian ini juga dipengaruhi oleh persiapan data, persiapan data yang dilakukan membantu meningkatkan akurasi yang dihasilkan. Hasil akurasi dengan persiapan data lebih baik daripada data tanpa persiapan data. Temuan ini diperkuat dengan temuan penelitian sebelumnya menyatakan persiapan data memiliki peranan penting dalam saat menggunakan mode neural network, karena mampu meningkatkan kualitas analisis, mempercepat proses pelatihan, mengurangi kesalahan pada saat pemodelan (Behera et al., 2021; Koval, 2018). Penelitian ini dapat terus ditingkatkan, di masa mendatang penelitian ini dapat diperluas pada lebih empat tingkat kematangan TBS kelapa sawit, mempertimbangkan melakukan klasifikasi tingkat kematangan TBS menggunakan model *deep learning* lain. Peningkatan kualitas dataset di masa mendatang dengan memperhatikan teknik akuisisi data untuk menghindari noise yang terjadi pada gambar. Terakhir, penelitian di masa mendatang dapat membandingkan learning rate dan optimizer lain

serta memperhatikan hyperparameter agar sesuai dengan dataset untuk klasifikasi tingkat kematangan TBS Kelapa sawit.

4. SIMPULAN

Pada penelitian ini diusulkan model ResNet50 untuk melakukan klasifikasi empat tingkat kematangan TBS kelapa sawit, model dilatih dengan melakukan augmentasi data dan eksperimen penyetelan input parameter optimizer, learning rate serta alokasi data. Berdasarkan hasil dan pembahasan yang telah dijabarkan sebelumnya didapati bahwa pada klasifikasi tingkat kematangan dapat dilakukan pada ResNet50 dengan dua percobaan hyperparameter. Model dengan optimizer adam diusulkan sebagai model klasifikasi tingkat kematangan TBS kelapa sawit dengan kemungkinan perbaikan dimasa mendatang.

5. DAFTAR PUSTAKA

- Albakri, Z. M., Saufi, M., Kassim, M., Abdullah, A. F., & Harith, H. H. (2019). SCIENCE & TECHNOLOGY Analysis of Oil Palm Leaf Phyllotaxis towards Development of Models to Determine the Fresh Fruit Bunch (FFB) Maturity Stages, Yield and Site-Specific Harvesting. *Pertanika J. Sci. & Technol*, 27(2), 659–672.
- Alfatni, M. S. M., Khairunniza-Bejo, S., Marhaban, M. H. B., Saaed, O. M. Ben, Mustapha, A., & Shariff, A. R. M. (2022). Towards a Real-Time Oil Palm Fruit Maturity System Using Supervised Classifiers Based on Feature Analysis. *Agriculture*, 12(9), 1461. <https://doi.org/10.3390/agriculture12091461>.
- Ashari, S., Yanris, G. J., & Purnama, I. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning. *Sinkron*, 7(2), 649–656. <https://doi.org/10.33395/sinkron.v7i2.11420>.
- Behera, S. K., Rath, A. K., & Sethy, P. K. (2021). Maturity status classification of papaya fruits based on machine learning and transfer learning approach. *Information Processing in Agriculture*, 8(2), 244–250. <https://doi.org/10.1016/j.inpa.2020.05.003>.
- Being, C. Y., Hashim, N., Maringgal, B., & Wondi, M. H. (2020). A review of non-destructive techniques applied for measuring quality of oil palm fresh fruit bunches. *Journal of Agricultural and Food Engineering*, 1(1), 1–6. <https://doi.org/10.37865/jafe.2020.0002>.
- Dermawan, D., & Ashari, M. L. (2018). Studi Pemanfaatan Limbah Padat Industri Pengolahan Minyak Kelapa Sawit Spent Bleaching Earth sebagai Pengganti Agregat pada Campuran Beton. *Jurnal Presipitasi*, 15(1), 7 – 10. <https://doi.org/10.14710/presipitasi.v15i1.7-10>.
- Fitra Maulana, F., & Rochmawati, N. (2019). Klasifikasi Citra Buah Menggunakan Convolutional Neural Network. *Journal of Informatics and Computer Science* 01(02), 104-108. <https://doi.org/10.26740/jinacs.v1n02.p104-108>.
- Ginanjar, T. (2022a). ImageClassificationReducedClass Dataset. *Roboflow Universe*.
- Ginanjar, T. (2022b). *imclassification Dataset*. Roboflow Universe.
- Hardi, A. D., Joni, R., Syukri, S., & Aziz, H. (2020). Pembuatan Karbon Aktif dari Tandan Kosong Kelapa Sawit sebagai Elektroda Superkapasitor. *Jurnal Fisika Unand*, 9(4), 479–486. <https://doi.org/10.25077/jfu.9.4.479-486.2020>.
- Herman, H., Susanto, A., Cenggoro, T. W., Suharjo, S., & Pardamean, B. (2020). Oil Palm Fruit Image Ripeness Classification with Computer Vision using Deep Learning and Visual Attention. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 12(2), 21–27. Retrieved from <https://jtec.utm.edu.my/jtec/article/view/5543>.
- Himmah, E. F., Widyaningsih, M., & Maysaroh, M. (2020). Identifikasi Kematangan Buah Kelapa Sawit Berdasarkan Warna RGB Dan HSV Menggunakan Metode K-Means Clustering. *Jurnal Sains Dan Informatika*, 6(2), 193–202. <https://doi.org/10.34128/jsi.v6i2.242>.
- Junkwon, P., Takigawa, T., Okamoto, H., Hasegawa, H., Koike, M., Sakai, K., Siruntawineti, J., Chaeychomsri, W., Vanavichit, A., Tittinuchanon, P., & Bahalayodhin, B. (2009). Hyperspectral imaging for nondestructive determination of internal qualities for oil palm (*Elaeis guineensis* Jacq. var. *tenera*). In *Agricultural Information Research* (Vol. 18, Issue 3). <https://doi.org/10.3173/air.18.130>.
- Khan, N., Kamaruddin, M. A., Sheikh, U. U., Yusup, Y., & Bakht, M. P. (2021). Oil palm and machine learning: Reviewing one decade of ideas, innovations, applications, and gaps. In *Agriculture (Switzerland)* (Vol. 11, Issue 9). MDPI. <https://doi.org/10.3390/agriculture11090832>.
- Koval, S. I. (2018). Data preparation for neural network data analysis. *Proceedings of the 2018 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering, ElConRus 2018, 2018-Janua*, 898–901. <https://doi.org/10.1109/ElConRus.2018.8317233>.
- Lai, J. W., Ramli, H. R., Ismail, L. I., & Hasan, W. Z. W. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4. *IEEE Access*, 10, 95763–95770.

- <https://doi.org/10.1109/ACCESS.2022.3204762>.
- Lye Chew, C., Yong Ng, C., Onn Hong, W., Yeong Wu, T., Lee, Y.-Y., Ee Low, L., San Kong, P., & Seng Chan, E. (2021). Improving Sustainability of Palm Oil Production by Increasing Oil Extraction Rate: a Review. *Food and Bioprocess Technology*. <https://doi.org/10.1007/s11947-020-02555-1/Published>.
- Mansour, M. Y. M. A., D. Dambul, K., & Choo, K. Y. (2022). Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch. *International Journal of Technology*, 13(6), 1326. <https://doi.org/10.14716/ijtech.v13i6.5932>.
- New-workspace-0vwie. (2021). *Sawit Dataset*. Roboflow Universe.
- Oktafanda, E. (2022). Klasifikasi Citra Kualitas Bibit dalam Meningkatkan Produksi Kelapa Sawit Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Informatika Ekonomi Bisnis*, 4(3), 72–77. <https://doi.org/10.37034/infec.v4i3.143>.
- Perez, L., & Wang, J. (2017). The Effectiveness of Data Augmentation in Image Classification using Deep Learning. *ArXiv*.
- Prakosa, P., Pattiasina, S., & Winanda, W. (2023). Ekoteologi Gereja Terhadap Penanaman Kelapa Sawit Di Lahan Gambut. *Jurnal Ilmiah Religiosity Entity Humanity (JIREH)*, 5(1), 73–82. <https://doi.org/10.37364/jireh.v5i1.124>.
- Prasetyo, N. A., Pranowo, & Santoso, A. J. (2020). Automatic detection and calculation of palm oil fresh fruit bunches using faster R-CNN. *International Journal of Applied Science and Engineering*, 17(2), 121–134. [https://doi.org/10.6703/IJASE.202005_17\(2\).121](https://doi.org/10.6703/IJASE.202005_17(2).121).
- Raj, T., Hashim, F. H., Huddin, A. B., Hussain, A., Ibrahim, M. F., & Abdul, P. M. (2021). Classification of oil palm fresh fruit maturity based on carotene content from Raman spectra. *Scientific Reports*, 11(1). <https://doi.org/10.1038/s41598-021-97857-5>.
- Rifqi, M. (2021). Deteksi Kematangan Tandan Buah Segar (Tbs) Kelapa Sawit Berdasarkan Komposisi Warna Menggunakan Deep Learning. *Jurnal Teknik Informatika*, 14(2). <https://doi.org/10.15408/jti.v14i2.23295>.
- Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtjas, H. P. A., Yustanti, W., & Prihanto, A. (2021). Analisa Learning Rate dan Batch Size pada Klasifikasi Covid Menggunakan Deep Learning dengan Optimizer Adam. *Journal of Information Engineering and Educational Technology*, 5(2), 44–48. <https://doi.org/10.26740/jieet.v5n2.p44-48>.
- Saleh, A. Y., & Liansitim, E. (2020). Palm oil classification using deep learning. *Science in Information Technology Letters*, 1(1), 1–8. <https://doi.org/10.31763/sitech.v1i1.1>.
- Saranya, N., Srinivasan, K., & Kumar, S. K. P. (2022). Banana ripeness stage identification: a deep learning approach. *Journal of Ambient Intelligence and Humanized Computing*, 13(8), 4033–4039. <https://doi.org/10.1007/s12652-021-03267-w>.
- Septiarini, A., Sunyoto, A., Hamdani, H., Kasim, A. A., Utaminingrum, F., & Hatta, H. R. (2021). Machine vision for the maturity classification of oil palm fresh fruit bunches based on color and texture features. *Scientia Horticulturae*, 286(April), 110245. <https://doi.org/10.1016/j.scienta.2021.110245>.
- Sinambela, R., Mandang, T., Subrata, I. D. M., & Hermawan, W. (2020). Application of an inductive sensor system for identifying ripeness and forecasting harvest time of oil palm. *Scientia Horticulturae*, 265. <https://doi.org/10.1016/j.scienta.2020.109231>.
- Suharjito, Elwirehardja, G. N., & Prayoga, J. S. (2021). Oil palm fresh fruit bunch ripeness classification on mobile devices using deep learning approaches. *Computers and Electronics in Agriculture*, 188. <https://doi.org/10.1016/j.compag.2021.106359>.
- Suyanto. (2017). *Data mining : untuk klasifikasi dan klasterisasi data*. Penerbit Informatika .
- Suyanto, Ramadhani, K. N., & Mandala, S. (2019). *Deep learning : modernisasi machine learning untuk big data*. Penerbit Informatika.
- Wang, Y., Liu, H., & Zhou, Y. (2021). Development of a deep learning-based model for the entire production process of steam-assisted gravity drainage (SAGD). *Fuel*, 287. <https://doi.org/https://doi.org/10.1016/j.fuel.2020.119565>.
- Wong, Z. Y., Chew, W. J., & Phang, S. K. (2020). Computer vision algorithm development for classification of palm fruit ripeness. *AIP Conference Proceedings*, 2233. <https://doi.org/10.1063/5.0002188>.
- Yuen Teh, W., Jaya, S., & Ian Tan, M. K. (2021). Coloured Edge Maps for Oil Palm Ripeness Classification Priority Dynamics. *The 32nd British Machine Vision Conference 22nd - 25th November 2021*.