

# PERBAIKAN MODEL ALEXNET UNTUK MENDETEKSI KEMATANGAN TBS KELAPA SAWIT DENGAN MENGGUNAKAN IMAGE ENHANCEMENT DAN HYPERPARAMETER TUNING

<sup>1</sup>Indra Alfredo, <sup>2</sup>Suharjito

<sup>12</sup>Computer Science Department, BINUS Graduate Program – Master of Computer Science, Bina Nusantara University, Jakarta

<sup>1</sup>indra.alfredo@binus.ac.id, <sup>2</sup>suharjito@binus.edu

## Abstrak

Kualitas CPO yang baik adalah dihasilkan dari buah sawit yang mempunyai tingkat kematangan yang baik. Pada umumnya penentuan kematangan TBS kelapa sawit dilakukan melalui penilaian warna buah secara visual dan subjektif, sehingga perlu dikembangkan suatu model untuk mengidentifikasi tingkat kematangan berdasarkan karakteristik warna. Adapun tujuan dari penelitian ini adalah untuk mengembangkan sebuah model deep learning agar mendapatkan hyperparameter terbaik dari model yang diteliti yaitu AlexNet untuk mengklasifikasi tingkat kematangan. Jumlah dataset yang digunakan terdiri dari 6.000 buah gambar kelapa sawit dengan enam tingkat kematangan. Teknik augmentation akan digunakan untuk membantu memperbanyak jumlah dataset, selain itu menambahkan parameter image enhancement untuk mencerahkan gambar agar lebih nyata. Parameter lainnya menggunakan binary crossentropy untuk mengurangi loss dan optimizer menggunakan Stochastic Gradient Descent (SGD) untuk menemukan nilai optimal. Kemudian dari hasil evaluasi initial model dilakukan hyperparameter tuning untuk mendapatkan optimal parameter dari model AlexNet yang dibangun. Dari hasil penelitian ini menunjukkan bahwa model yang diajukan menggunakan metode Convolutional Neural Network (CNN) dengan menggunakan model AlexNet akurasi meningkat setelah menggunakan hyperparameter tuning dan image enhancement berhasil mencapai 0.9530.

**Kata kunci:** AlexNet, Convolutional Neural Network, kelapa sawit, kematangan

## Abstract

Good quality CPO is produced from palm fruit that has a good maturity level. In general, satisfying oil palm FFB is done through visually and subjectively colorful, so it is necessary to develop a model to develop levels based on color characteristics. The purpose of this research is to develop a deep learning model in order to get the best hyperparameters from the studied model, namely AlexNet to classify maturity levels. The dataset used consists of 6,000 images of oil palms with six levels of maturity. Augmentation techniques will be used to help increase the number of datasets, in addition to adding image enhancement parameters to brighten images to make them more real. The other parameters use binary crossentropy to reduce losses and the optimizer uses Stochastic Gradient Descent (SGD) to find the optimal value. Then from the results of the initial model evaluation, hyperparameter adjustments were made to obtain the optimal parameters of the AlexNet model that was built. The results of this study indicate that the proposed model uses the Convolutional Neural Network (CNN) method using the AlexNet model, the accuracy increases after using hyperparameter tuning and image enhancement successfully reaches 0.9530.

**Keywords:** AlexNet, Convolutional Neural Network, maturity, oil palm

## PENDAHULUAN

Indonesia adalah salah satu produsen Crude Palm Oil (CPO) di dunia. Keberlangsungan produksi CPO Indonesia perlu dijaga karena industri kelapa sawit merupakan komoditas penunjang perekonomian Indonesia. Tingkat kematangan Tandan Buah Segar (TBS) kelapa sawit merupakan faktor penting sebagai penentu kualitas CPO yang dihasilkan. Tingkat kematangan yang sempurna adalah keadaan yang menghasilkan kandungan produk total yang maksimum [1]. Ada berbagai macam produk olahan TBS kelapa sawit yang digunakan dalam kehidupan sehari-hari di seluruh dunia, seperti margarin, sabun minyak goreng, dan lainnya [2]. Ada 3 faktor yang menentukan kualitas minyak sawit yaitu kematangan TBS, asam lemak bebas yang rendah dan tingkat ekstraksi minyak yang tinggi [3]. Penentuan tingkat kematangan secara tradisional yang masih mengandalkan tenaga manusia menyebabkan kualitas panen dipengaruhi pengalaman, keahlian, dan pengetahuan. Pemanenan secara tradisional ini juga bersifat subjektif, lambat dan tidak menyeluruh [4]. *Deep learning* telah menunjukkan hasil yang menjanjikan untuk mengklasifikasikan gambar, bahkan untuk kasus yang kompleks sekalipun. Dengan penekanan khusus pada penggunaan di sektor kelapa sawit, dimana penggunaan informasi dari kecerdasan buatan dalam proses produksi minyak dapat mengarah pada perbaikan besar terhadap

dampak ekonomi dan lingkungan [5]. Oleh karena itu, perlu dikembangkan sebuah model untuk mengidentifikasi tingkat kematangan berdasarkan ciri warna.

Penelitian identifikasi tingkat kematangan TBS kelapa sawit menggunakan *deep learning* sudah ada digunakan. Penelitian yang dilakukan [6] mengatakan *Convolutional Neural Networks* (CNNs) telah ditetapkan sebagai kelas model yang dominan untuk masalah klasifikasi gambar. Penelitian bertujuan untuk menerapkan dan menganalisis keakuratan *deep learning* untuk mengklasifikasikan buah masak pada buah kelapa sawit. CNN digunakan untuk mengklasifikasikan 628 gambar menjadi 2 kelas yang berbeda. Selanjutnya, eksperimen CNN dengan 5 epoch memberikan hasil klasifikasi yang menjanjikan dengan akurasi 98%, lebih baik dari metode sebelumnya. Kesimpulannya, penelitian ini berhasil menyelesaikan klasifikasi citra dengan mendeteksi dan membedakan kematangan buah kelapa sawit.

Penelitian [7] mengembangkan sebuah model menggunakan mekanisme *residual attention* agar model dapat mengenal perbedaan di antara gambar yang luput dari mata. *Dataset* yang digunakan terdiri dari 400 buah gambar dengan tujuh tingkat kematangan. Dikarenakan jumlah dataset yang kecil, maka teknik *preprocessing Ten Crop* akan digunakan untuk membantu memperbanyak jumlah gambar. Penelitian ini menunjukkan bahwa model yang dilakukan yaitu *ResAtt DenseNet* dapat meningkatkan akurasi sebesar

3.89%, dibandingkan dengan model *DenseNet* (*densenet121*) tanpa *Visual Attention*.

Penelitian [8], membuat aplikasi berbasis mobile, untuk mengklasifikasikan tingkat kematangan buah kelapa sawit menggunakan CNN. Pada penelitian ini implementasi proses *transfer learning* menggunakan ImageNet pada 4 model CNN *lightweight*, dengan augmentasi data yang dinamakan “*9-angle crop*”. Dari penelitian tersebut, transfer learning dan *9 angle crop* berhasil meningkatkan akurasi model dengan tetap menjaga kecepatan pemrosesan sehingga model dapat diimplementasikan pada perangkat seluler dan didapatkan akurasi sebesar 0.898 menggunakan model EfficientNetB0.

Penelitian [9], melakukan penelitian terhadap model EfficientNetB0 dan B1 untuk mendeteksi kematangan sawit ke dalam 6 kelas, yaitu TBS Kurang masak, TBS Masak, TBS Mentah, TBS terlalu masak, TBS abnormal dan janjang kosong menggunakan optimizer RMSprop dan SGD. Dari hasil penelitian, didapat akurasi tertinggi dengan menggunakan optimizer RMSprop sebesar 0.9955 menggunakan model EfficientNetB0 dan 0.9949 menggunakan model EfficientNetB1. Sementara menggunakan optimizer SGD, akurasi yang diraih.

Penelitian [10], melakukan penelitian dengan dataset sejumlah 120 gambar yang terdiri dari 4 tingkat kematangan dengan membandingkan antara *feature handcrafted* dan pendekatan pengklasifikasi yang terdiri dari tiga fitur berbeda yaitu momen warna,

FREAK dan HOG dengan pengklasifikasi SVM, CNN dan CNN yang dilatih sebelumnya yaitu model *AlexNet*, yang berfokus pada akurasi dan waktu pemrosesan. Performa CNN bergantung pada jumlah data pelatihan dan jumlah lapisan. Dengan menerapkan CNN dari awal membutuhkan data pelatihan yang sangat banyak untuk mencapai hasil yang relatif baik. Lapisan di dalamnya dapat memberikan hasil yang lebih baik tetapi menghasilkan waktu pemrosesan yang lambat. Hasil eksperimen menunjukkan bahwa *AlexNet* mengungguli dua pendekatan lainnya (*CNN dan Handcrafted Features*) karena memiliki lebih banyak lapisan di mana lebih banyak fitur dapat diekstraksi tetapi dengan waktu pemrosesan yang lebih tinggi. Penggunaan AlexNet cocok untuk mengklasifikasi di mana sejumlah besar data.

Pada penelitian ini, diharapkan dapat mengembangkan sebuah model *deep learning* agar mendapatkan *hyperparameter* terbaik dari model yang diteliti yaitu AlexNet untuk mengklasifikasi tingkat kematangan TBS kelapa sawit. Jumlah dataset yang digunakan terdiri dari 6.000 buah gambar kelapa sawit dengan enam tingkat kematangan. Teknik *augmentation* akan digunakan untuk membantu memperbanyak jumlah dataset, selain itu menambahkan parameter *image enhancement* untuk mencerahkan gambar agar lebih nyata. Parameter lainnya menggunakan binary crossentropy untuk mengurangi loss dan optimizer menggunakan Stochastic Gradient Descent (SGD) untuk menemukan nilai

optimal. Kemudian dari hasil evaluasi initial model dilakukan proses *hyperparameter tuning* dan *image enhancement* untuk mendapatkan *optimal parameter* dari model AlexNet yang dibangun.

## METODE PENELITIAN

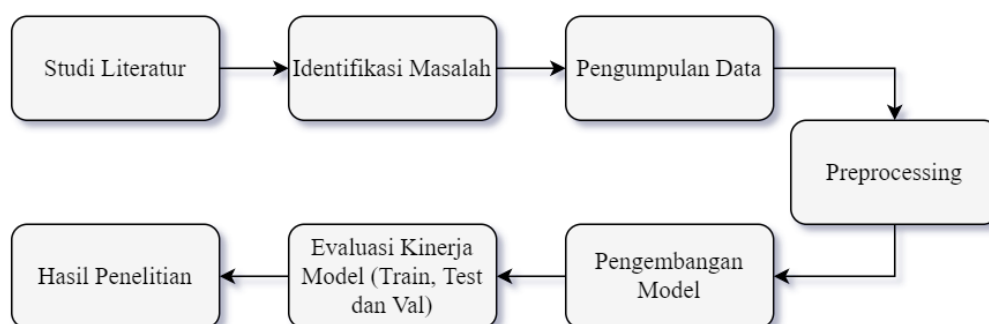
### 1. Tahapan Penelitian

Adapun tahapan yang dilakukan dalam penelitian ini adalah sebagai berikut.

Pada Gambar 1, tahap awal yaitu studi literatur merupakan studi mengenai literatur-literatur yang dilakukan untuk mendukung penelitian. Penelitian ini difokuskan pada identifikasi tingkat kematangan tandan buah segar kelapa sawit menggunakan *deep learning* dengan metode *Convolutional Neural Network* model AlexNet. Pada tahap identifikasi masalah, yaitu melihat dari keadaan dilapangan pada permasalahan identifikasi tandan buah segar di perusahaan kelapa sawit, yang mana masih ada perbedaan tentang mengidentifikasi tingkat kematangan. Melalui sumber dataset foto-foto di lapangan

yang ada maka akan dapat membantu membangun model AlexNet dalam pengolahan untuk mengidentifikasi tingkat kematangan.


Di dalam pengumpulan data untuk mendapatkan gambar lebih banyak dari gambar yang sudah ada sebelumnya dilakukan proses *augmentasi*. Beberapa metode yang dapat digunakan untuk meningkatkan jumlah data dengan melakukan augmentasi ini diantaranya adalah: pantulan bayangan baik horizontal maupun vertikal (flip), peningkatan kontras, pergeseran dan rotasi [11]. Kemudian dari data tersebut dilakukan lah proses *pre-processing* dengan menentukan label dari setiap data. Kemudian gambar yang telah diambil disamakan ukuran atau resolusinya, pada penelitian ini resolusi yang digunakan adalah 128x128 piksel. Kemudian dilakukan analisa dan evaluasi terkait model yang telah dibangun. Proses selanjutnya adalah evaluasi kinerja model yang sudah dibangun melalui data *training*, *test* dan *validasi* dan menghasilkan akurasi dari model. Adapun *resource* yang digunakan pada penelitian ini ditunjukkan pada Tabel 1.



Gambar 1. Tahapan Penelitian

Tabel 1. Spesifikasi Resource Compute Engine

Platform	Google Colab Pro
Graphical Processing Units	NVIDIA Tesla P100 / NVIDIA T4
CPUs	2 x vCPU
RAM	24
Storage	200 GB
Hardware Accelerator	GPU
Runtime Shape	High-RAM



Gambar 2. Ilustrasi Struktur Convolutional Neural Network (CNN), [12]

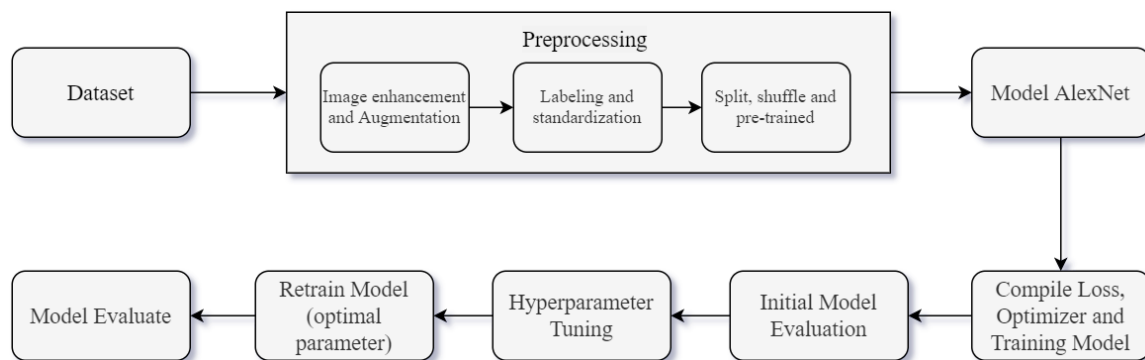
## 2. Model Yang Diusulkan

*Convolutional Neural Network* (CNN/ConvNet) adalah salah satu algoritma dari *deep learning* yang merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang dirancang untuk mengolah data dalam bentuk dua dimensi, misalnya gambar atau suara. CNN digunakan untuk mengklasifikasi data yang terlabel dengan menggunakan metode *supervised learning*. Cara kerja dari *supervised learning* adalah terdapat data yang dilatih dan terdapat variabel yang ditargetkan sehingga tujuan dari metode ini adalah mengelompokan suatu data ke data yang sudah ada. Adapun ilustrasi struktur dari *Convolutional Neural Network* (CNN) dapat dilihat pada Gambar 2.

Model yang diusulkan adalah pada penelitian ini terdiri dari beberapa tahapan

yang dapat dilihat dari Gambar 3

Pada Gambar 3, tahap awal adalah *input images dataset* TBS kelapa sawit, kemudian dilakukan proses *images enhancement* untuk mencerahkan gambar agar lebih berwarna dan *process augmentation* yang digunakan untuk memperbanyak dan mengatur jumlah gambar yang akan digunakan. Selanjutnya proses label untuk mengkonversi data kategori atau data teks menjadi angka agar lebih mudah dipahami, kemudian proses standarisasi yang merupakan prosedur standard sebelum data mulai di training dan dataset di split menjadi data training, test dan validasi, dengan ratio 7:2:1. Di dalam proses ini juga terdapat proses *process image* yaitu *image* yang ada kemudian di kecilkan dan di *shuffle* dan dibagi dalam *batch*.



Gambar 3. Model Yang Diusulkan

Pada hal ini *AlexNet* yang selanjutnya dilakukan proses awal training model. *AlexNet* arsitekturnya terdiri dari CNN 2 dimensional, normalisasi, *maxpool* dan kembali ke tahap CNN lagi, kemudian proses flatten untuk menjadikan 1 dimensi (128x128,3) proses *dense* yaitu memampatkan, proses *rectified linear unit* (ReLU), dan proses *softmax* sebagai aktivasinya. Selanjutnya juga terdapat proses *compile loss* untuk menghitung *loss function* (*loss*, *optimize* dan *accuration*) dalam hal ini menggunakan *binary\_crossentropy* yang merupakan model paling cocok untuk melakukan klasifikasi biner, dimana nilai target berada di set {0, 1}. Selanjutnya proses *optimize* menggunakan *Stochastic Gradient Descent* (SGD) untuk menemukan nilai optimal.

Selanjutnya, model telah dapat dibangun dengan menggunakan data *training* dan data validasi tadi. Dengan menentukan *epoch*, yaitu *hyperparameter* yang menentukan berapa kali algoritma pembelajaran akan bekerja melalui seluruh *training dataset*. Semakin tinggi nilai *epoch*-nya, maka akan semakin baik akurasi yang didapat, namun

akan semakin panjang prosesnya dan tentu saja akan memakan waktu lebih lama, sehingga dalam penelitian ini akan menggunakan parameter *Early Stopping* untuk dapat membantu menentukan banyaknya jumlah periode training dan menghentikan training setelah kinerja model berhenti meningkat pada validasi dataset. Setelah model berhasil dibangun maka didapatkan hasil initial model untuk *AlexNet*. Dari hasil initial model ini pada model *AlexNet* dilakukan proses *hyperparameter tuning* dengan arsitektur yang masih sama untuk kembali mencari nilai parameter yang paling terbaik, dan terakhir adalah mengevaluasi dari model yang dibangun.

## HASIL DAN PEMBAHASAN

### 1. Dataset

Pengujian dengan total jumlah 6.000 citra atau *images* TBS kelapa sawit dengan spesifikasi seperti ditunjukkan pada Tabel 2. Melalui data tersebut kemudian dilakukan augmentasi untuk mencapai data yang banyak untuk menghasilkan model yang baik.

Augmentasi data adalah proses untuk mendapatkan gambar lebih banyak dari gambar yang sudah ada sebelumnya. Beberapa metode yang dapat digunakan untuk meningkatkan jumlah data dengan melakukan augmentasi ini diantaranya adalah: pantulan bayangan baik horizontal maupun vertikal (flip), peningkatan

kontras, pergeseran dan rotasi [9]. Hasil augmentasi data ditunjukkan pada Tabel 3.

Pada Tabel 4, merupakan contoh gambar dataset yang digunakan, terbagi dalam enam kelas yaitu TBS mentah, TBS mengkal, TBS matang, TBS terlalu matang, TBS abnormal dan TBS janjang kosong.







Tabel 2. Jumlah Dataset Sebelum Proses Augmentasi

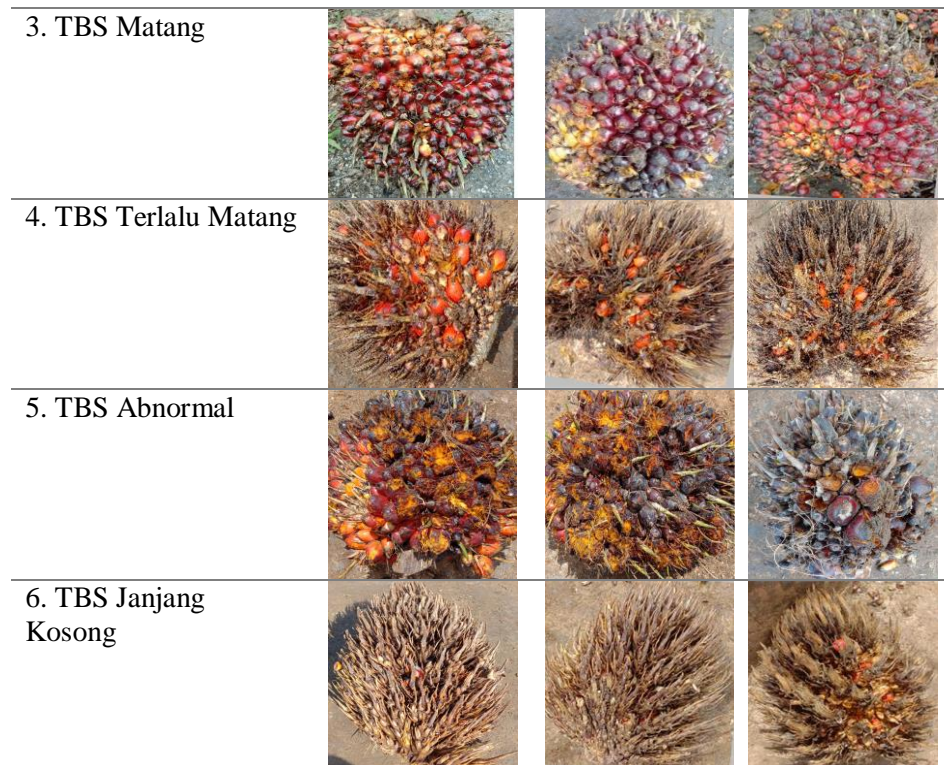
Deskripsi	Training (70%)	Test (20%)	Validasi (10%)	Jumlah
TBS Mentah	700	200	100	1.000
TBS Mengkal	700	200	100	1.000
TBS Matang	700	200	100	1.000
TBS Terlalu Matang	700	200	100	1.000
TBS Abnormal	700	200	100	1.000
TBS Janjang Kosong	700	200	100	1.000
TOTAL	4.200	1.200	600	6.000

Tabel 3. Jumlah Dataset Sesudah Proses Augmentasi

Deskripsi	Training (70%)	Test (20%)	Validasi (10%)	Jumlah
TBS Mentah	2.100	600	300	3.000
TBS Mengkal	2.100	600	300	3.000
TBS Matang	2.100	600	300	3.000
TBS Terlalu Matang	2.100	600	300	3.000
TBS Abnormal	2.100	600	300	3.000
TBS Janjang Kosong	2.100	600	300	3.000
TOTAL	12.600	3.600	1.800	18.000

Tabel 4. Cuplikan Dataset

Kelas	Gambar 1	Gambar 2	Gambar 3
1. TBS Mentah			
2. TBS Mengkal			



## 2. Pre-processing Data

Pada tahap pre-processing ada 3 bagian proses yang dilakukan pertama yaitu proses *feature extraction and augmentation*, *labeling and standardization*, dan terakhir *split, shuffle and pre-trained*. Dataset yang digunakan di tetapkan sebanyak 1.000 gambar per-masing-masing kelas, kemudian di resize 128 x 128 piksel dan digunakan *image*

*enhancement* sebanyak 3 dan augmentasi sebanyak 2 kali, adapun parameter tersebut dapat dilihat pada Tabel 5.













Pada Tabel 6, menjelaskan *images* dataset sebelum *enhancement* dan dataset setelah mengalami *enhancement*, dapat dilihat *images* yang sebelumnya kurang terang menjadi lebih cerah.

Tabel 5. Pre-processing Image Enhancement dan Augmentation

Parameter	Nilai
os.listdir(folder)	[:1000]
resize	128, 128
Image.enhance.Color	3
rotate	90, 180



Tabel 6. Hasil Images Enhancement

Kelas	Dataset Sebelum Enhancement	Dataset Setelah Enhancement
1. TBS Mentah		
2. TBS Mengkal		
3. TBS Matang		
4. TBS Terlalu Matang		
5. TBS Abnormal		
6. TBS Janjang Kosong		

## 2. Hasil Evaluasi

Performa dari setiap model dilihat dari klasifikasi akurasi. Di mana model yang terbaik akan didapat dari melihat hasil akurasi. Untuk mendapatkan model dengan akurasi yang baik, perlu dilakukan penyesuaian model. Dari hasil *initial model* yang telah dibangun, didapat hasil pada Tabel 7.


Untuk meningkatkan akurasi dari hasil initial model *AlexNet* maka dilakukan proses *hyperparameter tuning*. Pada *standard value* merupakan nilai standard dari model *AlexNet* dan parameter value merupakan range untuk mendapatkan *optimal value*, hasil *hyperparameter tuning* dapat dilihat pada Tabel 8.

Tabel 7. Parameter Yang Digunakan

Model	Total Parameter	Trainable Parameter	Non-trainable parameter
AlexNet (Sebelum menggunakan Hyperparameter Tuning)	24,756,998	24,754,246	2,752
AlexNet (Setelah menggunakan Hyperparameter Tuning)	44,431,750	44,427,910	3,840

Tabel 8. Hasil Hyperparameter Tuning AlexNet

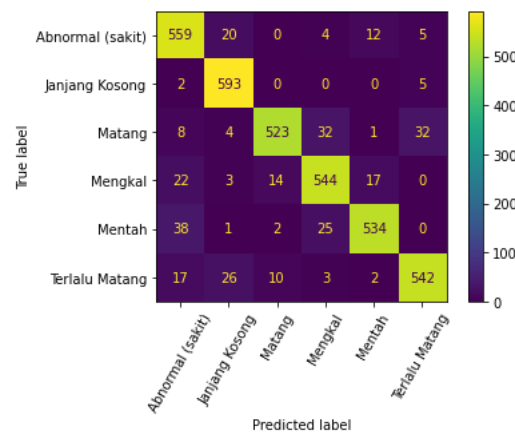
Hyperparameter	Standard Value	Parameter Value	Optimal Value
Conv2D	filters=96	min_value=96, max_value=256, default=96	256
Conv2D	filters=256	min_value=256, max_value=512, default=256	448
Conv2D	filters=384	min_value=384, max_value=512, default=384	448
Conv2D	filters=384	min_value=384, max_value=512, default=384	416
Conv2D	filters=256	min_value=256, max_value=512, default=256	480
Dense	filters=4096	min_value=4096, max_value=8192, default=4096	7168
Dense	filters=4096	min_value=4096, max_value=8192, default=4096	7424



Gambar 4. Accuracy dan Loss model AlexNet



Gambar 4. Precision dan Recall model AlexNet



Gambar 5. Confusion Matrix Hasil Pengujian Model

Dari Gambar 4, model AlexNet yang dibangun menggunakan parameter *early stopping* menunjukkan epoch sudah *convergence* saat memasuki epoch lebih dari 25. Begitu pun untuk nilai *loss*, *precision* dan *recall* mulai *convergence* di epoch lebih dari 25.

Hasil klasifikasi dari model yang sudah di bangun akan dihadirkan dalam bentuk *confusion matrix* yaitu dengan membandingkan nilai aktual (True Label) dan nilai prediksi (Predict Label) yang terdapat pada Gambar 5 di bawah ini.

Pada Tabel 9, dapat dilihat bahwa

dengan menggunakan parameter *image enhancement* dapat meningkatkan nilai *accuracy* pada model AlexNet, yang sebelumnya 0,8666 setelah menggunakan *image enhancement* menjadi 0,8999 mengalami peningkatan sebesar 0,033 (3,3%). Dengan *image enhancement* memperoleh image yang lebih sesuai digunakan untuk aplikasi lebih lanjut dan dapat membantu meningkatkan kinerja CNN [13].

Hasil akurasi yang di dapatkan dari *image enhancement* akan dibandingkan dengan model AlexNet yang telah dilakukan oleh penelitian [10].

Tabel 9. AlexNet Menggunakan Image Enhancement

Nama Model	Accuracy
AlexNet (Sebelum menggunakan Image Enhancement) [10]	0.8666
AlexNet (Setelah menggunakan Image Enhancement)	0.8999

Tabel 10. AlexNet Menggunakan Hyperparameter Tuning

Nama Model	Accuracy
AlexNet (Sebelum menggunakan Hyperparameter Tuning) [10]	0.9230
AlexNet (Setelah menggunakan Hyperparameter Tuning)	0.9530

Dari Tabel 10 dapat dilihat bahwa dengan menggunakan parameter *hyperparameter tuning* dapat meningkatkan nilai *accuracy* pada model AlexNet, yang sebelumnya 0,9230 setelah menggunakan *hyperparameter tuning* menjadi 0,9530 mengalami peningkatan sebesar 0,03 (3%).

Hasil akurasi yang di dapatkan dari *hyperparameter tuning* akan dibandingkan dengan model AlexNet yang telah dilakukan oleh penelitian [10].

## KESIMPULAN DAN SARAN

Berdasarkan dari penelitian yang dilakukan, dapat diambil beberapa kesimpulan antara lain yaitu, model AlexNet telah berhasil dibangun dengan menggunakan dataset yang terdiri dari TBS kurang masak, TBS masak, TBS mentah, TBS terlalu mentah, TBS abnormal dan janjang kosong. Dari model *AlexNet* yang dibangun hasil akurasi dari evaluasi initial model yaitu 0.8666, setelah model dilakukan proses *image enhancement* dan *hyperparameter tuning* memiliki nilai akurasi yang lebih baik yaitu 0.9530

Berdasarkan hasil penelitian yang dilakukan, dapat diberikan beberapa saran untuk meningkatkan kontribusi penelitian selanjutnya antara lain yaitu menggunakan proses *hyperparameter tuning* di model DenseNet121, RestNet50 dan VGG16. Menggunakan metode optimizer lain, misalnya Adam, Adadelta, Adagrad, Adamax, dan Nadam dan terakhir yaitu menggunakan layanan Google Colab Pro + untuk dapat memproses jumlah data yang besar untuk mendapatkan hasil yang optimal.

## DAFTAR PUSTAKA

- [1] M. H. Razali, S. Abdul and R. Syazili, "A Review on Crop Plant Production and Ripeness Forecasting," *International Journal of Agriculture and Crop Sciences (IJACS)*, vol. 4, no. 2, hal. 54-63, 2012.
- [2] S. A. Ghazalli, H. Selamat, Z. Omar and R. Yusof, "Image Analysis Techniques for Ripeness Detection of Palm Oil Fresh Fruit Bunches," *ELEKTRIKA-Journal of Electrical Engineering*, vol. 18, no. 3, hal. 57-62, 2019.
- [3] Z. B. M. Sharif, N. B. M. Taib, M. S. B.

- Yusof, M. Z. B. Rahim, A. L. B. M. Tobi and M. S. B. Othman, "Study on Handling Process and Quality Degradation of Oil Palm Fresh Fruit Bunches (FFB)," *IOP Conference Series: Materials Science and Engineering*, vol. 203, no.1, hal. 012027, 2017.
- [4] M. H. M. Hazir, A. R. M. Shariff and M. D. Amiruddin, "Determination of Oil Palm Fresh Fruit Bunch ripeness-Based on Flavonoids and Anthocyanin Content," *Industrial Crops and Products*, vol. 36, no. 1, hal. 466-475, 2012.
- [5] I. Bonet, F. Caraffini, A. Pena, A. Puerta and M. Gongora, "Oil Palm Detection via Deep Transfer Learning," *In 2020 IEEE Congress on Evolutionary Computation (CEC)*, hal. 1-8, July, 2020.
- [6] A. Y. Saleh and E. Liansitim, "Palm Oil Classification Using Deep Learning," *Sci. Inf. Technol. Lett*, vol. 1, no. 1, hal. 1-8, 2020.
- [7] H. Herman, A. Susanto, T. W. Cenggoro, S. Suharjo and B. Pardamean, "Oil Palm Fruit Image Ripeness Classification with Computer Vision using Deep Learning and Visual Attention," *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, vol. 12, no. 2, hal. 21-27, 2020.
- [8] G. N. Elwirehardja, J. S. Prayoga and Suharjo, "Oil Palm Fresh Fruit Bunch Ripeness Classification On Mobile Devices Using Deep Learning Approaches," *Computers and Electronics in Agriculture*, vol. 188, hal. 106359, 2021.
- [9] M. Rifqi and Suharjo, "Deteksi Kematangan Tandan Buah Segar (Tbs) Kelapa Sawit Berdasarkan Komposisi Warna," *Jurnal Teknik Informatika*, vol. 14, no. 2, hal. 125-134, 2021.
- [10] Z. Ibrahim, N. Sabri and D. Isa, "Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network," *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, vol. 10, no. 3-2, hal. 109-113, 2018.
- [11] T. A. Korzhebin and A. D. Egorov, "Comparison of Combinations of Data Augmentation Methods and Transfer Learning Strategies in Image Classification Used in Convolution Deep Neural Networks," *2021 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*, hal. 479-482, 2021.
- [12] Y. LeCun, L. Bottou, Y. Bengio and P. & Haffner, "Gradient-Based Learning Applied to Document Recognition," *Proceedings of the IEEE*, vol. 86, no. 11, hal. 2278-2324, 1998.
- [13] X. Chen, "Image Enhancement Effect On The Performance Of Convolutional Neural Networks," Tesis, Department of Computer Science, Faculty of Computing, Blekinge Institute of Technology, Sweden, 2019.