

Metode Klasifikasi Kematangan Tandan Buah Segar Kelapa Sawit: Sebuah Tinjauan Sistematis

Nurita Evitarina^{1✉}, Kusrini Kusrini²

^{1,2} Informatika, PJJ MTI, Universitas Amikom Yogyakarta, Indonesia

Informasi Artikel

Riwayat Artikel

Diserahkan : 26-07-2024

Direvisi : 05-08-2024

Diterima : 08-08-2024

Kata Kunci:

Deep Learning, Klasifikasi Kematangan, Kelapa Sawit, Tandan Buah Segar

Keywords :

Deep Learning, Maturity Classification, Palm Oil, Fresh Fruit Bunches

ABSTRAK

Penentuan kematangan buah kelapa sawit sangat penting untuk meningkatkan kualitas dan kuantitas produksi minyak kelapa sawit. Penelitian ini mengkaji penggunaan teknologi *deep learning* untuk mengklasifikasikan kematangan kelapa sawit melalui *Systematic Literature Review* (SLR). Metode penelitian yang digunakan adalah *Systematic Literature Review* (SLR) yang melibatkan analisis 35 jurnal dari Scopus dan Google Scholar dari tahun 2020 hingga 2024, dengan fokus pada kumpulan data, algoritma, lokasi kumpulan data, dan metode pengukuran kinerja model. Hasilnya menunjukkan bahwa ANN dan CNN adalah algoritma yang paling banyak digunakan, dengan penggunaan masing-masing 16% dan 10%. Akurasi, presisi, perolehan, dan skor F1 adalah metrik kinerja yang paling umum. Penelitian di masa depan harus fokus pada peningkatan generalisasi model dan mengintegrasikan data dari berbagai sumber untuk meningkatkan akurasi klasifikasi, tujuannya untuk berkontribusi pada klasifikasi kematangan minyak sawit dan membantu industri meningkatkan efisiensi dan kualitas produksi.

ABSTRACT

Determining the maturity of palm oil fruit is very important to improve the quality and quantity of palm oil production. This research examines the use of deep learning technology to classify oil palm maturity through a Systematic Literature Review (SLR). The research method used is a Systematic Literature Review (SLR) which involves analysis of 35 journals from Scopus and Google Scholar from 2020 to 2024, with a focus on datasets, algorithms, dataset locations, and methods for measuring model performance. The results show that ANN and CNN are the most widely used algorithms, with usage of 16% and 10% respectively. Accuracy, precision, recall, and F1 score are the most common performance metrics. Future research should focus on improving model generalization and integrating data from multiple sources to improve classification accuracy, the aim of which is to contribute to palm oil maturity classification and help the industry improve production efficiency and quality.

Corresponding Author :

Nurita Evitarina

Informatika, PJJ MTI, Universitas Amikom Yogyakarta, Indonesia

Jl. Ring Road Utara, Ngringin, Condongcatur, Kec. Depok, Kabupaten Sleman, Daerah Istimewa Yogyakarta

Email: nuritaevitarina15@gmail.com

PENDAHULUAN

Kelapa sawit (*Elaeis guineensis*) adalah salah satu tanaman kebun dengan nilai ekonomi tinggi, terutama dalam produksi minyak kelapa sawit yang digunakan di berbagai industri seperti

pangan, kosmetik, dan biofuel. Di Indonesia, industri kelapa sawit berkembang pesat dan menjadi salah satu pilar ekonomi nasional. Pada tahun 2023 mencapai 16,8 juta hektar luas area perkebunan kelapa sawit di Indonesia, menunjukkan pertumbuhan signifikan dibandingkan tahun-tahun sebelumnya (Databoks, 2024).

Penentuan tingkat kematangan buah kelapa sawit adalah langkah krusial dalam proses produksi minyak kelapa sawit karena kematangan yang tepat memaksimalkan kualitas dan kuantitas minyak yang dihasilkan. Metode konvensional untuk menentukan kematangan buah sering kali subjektif dan memerlukan banyak tenaga kerja. Namun, dengan kemajuan teknologi, khususnya *deep learning*, solusi yang lebih efisien dan akurat dapat diterapkan. *Deep learning*, bagian dari kecerdasan buatan, dapat digunakan untuk mengembangkan model yang mampu mengidentifikasi dan mengklasifikasikan tingkat kematangan buah kelapa sawit berdasarkan citra visual.

Berbagai penelitian telah mengaplikasikan teknologi *deep learning* dalam pertanian, khususnya untuk klasifikasi tingkat kematangan buah. Penelitian-penelitian ini umumnya berfokus pada pengembangan model berbasis *Convolutional Neural Networks* (CNN) yang efektif dalam pengenalan pola dan analisis citra. Studi-studi terdahulu menunjukkan bahwa model *deep learning* mampu mencapai akurasi tinggi dalam klasifikasi tingkat kematangan buah kelapa sawit, meskipun masih terdapat tantangan dalam hal generalisasi model dan pengolahan data yang bervariasi.

Penelitian ini bertujuan untuk melakukan kajian literatur sistematis mengenai aplikasi *deep learning* dalam klasifikasi tingkat kematangan buah kelapa sawit. Tujuan utama dari penelitian ini adalah mengidentifikasi tren dan perkembangan terbaru dalam penggunaan *deep learning*, mengevaluasi metodologi yang digunakan dalam penelitian terdahulu, serta mengidentifikasi tantangan dan peluang untuk penelitian di masa depan. Penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang pertanian presisi, khususnya dalam meningkatkan efisiensi dan akurasi penentuan tingkat kematangan buah kelapa sawit. Selain itu, penelitian ini juga bertujuan untuk memberikan wawasan yang komprehensif bagi peneliti dan praktisi, membantu industri kelapa sawit dalam mengadopsi teknologi baru, serta menyediakan panduan bagi penelitian selanjutnya dalam mengatasi tantangan dan memanfaatkan peluang dalam aplikasi *deep learning* di bidang pertanian.

METODE PENELITIAN

Systematic Literature Review (SLR) adalah metode penelitian yang digunakan untuk mengidentifikasi, mengevaluasi, dan menginterpretasi semua penelitian yang relevan terkait dengan pertanyaan penelitian tertentu, topik, atau fenomena minat. SLR bertujuan untuk menyediakan ringkasan komprehensif dari bukti yang ada yang dapat digunakan untuk menjawab pertanyaan penelitian tertentu. SLR dilakukan dengan cara yang sistematis dan transparan untuk meminimalkan bias dan menghasilkan hasil yang dapat diandalkan.

Proses SLR terdiri dari beberapa langkah penting yang harus diikuti untuk memastikan hasil penelitian yang valid dan dapat diandalkan. Langkah-langkah tersebut adalah menentukan research question, mendesain perencanaan penelitian, pengumpulan data, penilaian kualitas studi, merancang analisis data, dan merancang sintesis data.

Langkah pertama dalam SLR adalah menentukan research question. Tahap ini bertujuan untuk merumuskan pertanyaan penelitian yang jelas dan spesifik yang akan menjadi fokus dari SLR. Pertanyaan penelitian ini penting karena akan menentukan arah dan ruang lingkup penelitian, serta membantu mengidentifikasi studi yang relevan dan informasi yang diperlukan untuk menjawab pertanyaan tersebut.

Tabel 1. Research Question

No.	Research Question	Tujuan
RQ1	Jenis dataset apa yang digunakan untuk mengklasifikasikan tingkat kematangan buah kelapa sawit?	Mengidentifikasi jenis dataset yang digunakan untuk klasifikasi tingkat kematangan buah kelapa sawit.
RQ2	Algoritma/model mana yang paling umum diterapkan untuk klasifikasi kematangan buah kelapa sawit?	Menentukan algoritma/model yang paling umum diterapkan dalam studi terbaru untuk klasifikasi kematangan buah kelapa sawit.
RQ3	Dari mana dataset untuk klasifikasi kematangan buah kelapa sawit biasanya dikumpulkan?	Mengidentifikasi lokasi umum pengumpulan dataset untuk klasifikasi kematangan buah kelapa sawit.
RQ4	Metode apa yang digunakan untuk mengukur kinerja hasil klasifikasi dalam studi tentang klasifikasi kematangan buah kelapa sawit?	Mengeksplorasi metode yang digunakan untuk mengukur kinerja hasil klasifikasi dalam studi tentang klasifikasi kematangan buah kelapa sawit.

Selanjutnya, mendesain perencanaan penelitian adalah tahap kedua yang bertujuan untuk merancang rencana penelitian yang rinci, termasuk strategi pencarian literatur, kriteria inklusi dan eksklusi, serta metode analisis data. Mendesain perencanaan penelitian ini penting karena memastikan bahwa proses SLR dilakukan secara sistematis dan terstruktur, sehingga hasilnya dapat diandalkan dan dapat direplikasi oleh peneliti lain.

Tahap ketiga adalah penilaian kualitas studi, yang bertujuan untuk mengevaluasi kualitas studi yang ditemukan selama proses pencarian literatur. Penilaian kualitas studi ini penting karena membantu mengidentifikasi penelitian yang memiliki metodologi yang kuat dan valid, sehingga hasil SLR tidak terpengaruh oleh studi yang memiliki kelemahan metodologis.

Pengumpulan data adalah tahap keempat, yang melibatkan pengumpulan data dari 35 jurnal penelitian yang diambil dari database jurnal Scopus dan Google Scholar dari tahun 2020 hingga 2024. Pengumpulan data yang komprehensif dan sistematis dari sumber-sumber terpercaya memastikan bahwa SLR mencakup berbagai penelitian yang relevan dan terbaru.

Pada tahap kelima, data yang telah dikumpulkan dianalisis menggunakan metode yang sesuai untuk menjawab pertanyaan penelitian. Analisis data dirancang untuk mengidentifikasi pola, tren, dan kesenjangan dalam literatur yang ada. Tahap ini penting untuk memberikan pemahaman yang mendalam tentang topik penelitian dan untuk menyusun sintesis yang akurat dari temuan-temuan yang relevan.

Tahap terakhir adalah merancang sintesis data, yaitu proses menggabungkan hasil analisis dari berbagai studi menjadi suatu kesimpulan yang kohesif. Merancang sintesis data ini penting karena menyediakan ringkasan komprehensif dari bukti yang ada, sehingga dapat memberikan jawaban yang jelas terhadap pertanyaan penelitian dan mengidentifikasi area yang memerlukan penelitian lebih lanjut.

HASIL DAN PEMBAHASAN

Sebanyak 35 jurnal dikumpulkan dari database Scopus dan Google Scholar seperti ditunjukkan pada Tabel 2. Jurnal-jurnal ini dikumpulkan dari periode 4 tahun terakhir, yaitu dari tahun 2020 hingga 2024, dengan kata kunci pencarian "*Classification Oil Palm Fruit Ripeness*". Jenis publikasi yang dikumpulkan adalah jurnal ilmiah.

Tabel 2 menunjukkan rincian jumlah publikasi yang diidentifikasi, termasuk informasi mengenai penulis, judul, tahun publikasi, dan sumber jurnal. Jurnal-jurnal ini mencakup berbagai studi yang berfokus pada penerapan *deep learning* dalam klasifikasi tingkat kematangan buah kelapa sawit, memberikan pandangan yang komprehensif tentang perkembangan terbaru dan tren dalam bidang ini.

Analisis terhadap publikasi ini membantu dalam mengevaluasi efektivitas model *deep learning*, metode klasifikasi yang digunakan, serta metode pengukuran hasil klasifikasi yang diterapkan. Selain itu, studi-studi ini juga mengungkapkan berbagai tantangan dan peluang yang

ada dalam penelitian klasifikasi kematangan buah kelapa sawit menggunakan teknik deep learning.

Pengumpulan data dari dua sumber database yang terkemuka, yaitu Scopus dan Google Scholar, memastikan bahwa literatur yang digunakan dalam kajian ini memiliki kredibilitas tinggi dan relevan dengan topik penelitian. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang klasifikasi kematangan buah kelapa sawit menggunakan teknologi *deep learning*.

Tabel 2. Jurnal Referensi

No	Referensi	No	Referensi
[J1]	Bonet, I., et al. (2024).	[J19]	Luddin, M. H. M., & Rahman, M. A. (2022).
[J2]	Pusadan, M. Y., et al. (2023).	[J20]	Zolfagharnassab, S., et al (2022)
[J3]	Suharjo, et al. (2023).	[J21]	Fauziah, W.K., et al. (2021).
[J4]	Saifullah, S., et al. (2023).	[J22]	Makky, M., et al (2021).
[J5]	Zamri, N. M., et al. (2023).	[J23]	Suharjo, et al. (2021).
[J6]	Wang, H. H., et al. (2023).	[J24]	Melidawati, et al. (2021).
[J7]	Shiddiq, M., et al. (2024).	[J25]	Septiarini, A., et al. (2020).
[J8]	Salim, E., & Suharjo. (2023).	[J26]	Husin, H.S., et al. (2021).
[J9]	Azman, H., & Suriani, N. S. (2023).	[J27]	Teh, W. Y., & Tan, I. K. T. (2021).
[J10]	Siricharoen, P., et al. (2023).	[J28]	Raj, T., et al. (2021).
[J11]	Gulzar, Y. (2023).	[J29]	Junos, M.H., et al. (2021).
[J12]	Mamat, N., et al. (2023).	[J30]	Setiawan, A.W., et al. (2020).
[J13]	Suharjo, Junior, F. A., et al. (2023).	[J31]	Herman, H., et al. (2020).
[J14]	Alfatni, M. S. M., et al. (2022).	[J32]	Septiarini, A., et al. (2021).
[J15]	Ismail, N., & Malik, O. A. (2022).	[J33]	Aliteh, N.A., et al. (2021).
[J16]	Tzuan, G.T.H., et al. (2022).	[J34]	Mohd Ali, M., et al. (2020).
[J17]	Mansour, M. Y. M. A., et al. (2022).	[J35]	Alfatni, M.S.M., et al. (2020).
[J18]	Azmi, M.H.I.M., et al. (2022).		

RQ1 : Dataset yang Digunakan

Metode klasifikasi kematangan tandan buah segar kelapa sawit (FFB) dan buah kelapa sawit menggunakan berbagai tipe dataset telah dijelaskan dalam penelitian ini. Metode Raman Spectra menggunakan dataset berupa buah kelapa sawit dengan persentase 6%. Metode ini memungkinkan deteksi komposisi kimia yang tepat untuk menentukan tingkat kematangan buah. Metode *Thermal Imaging* menggunakan citra termal untuk mendeteksi perbedaan suhu yang dihasilkan oleh buah pada berbagai tingkat kematangan, juga dengan persentase 6%. *Colour Vision* adalah metode yang paling umum digunakan, dengan persentase 16%, menggunakan analisis warna untuk mengklasifikasikan kematangan FFB dan buah kelapa sawit karena perbedaan warna yang jelas antara buah yang matang dan belum matang. Metode LiDAR Sensor menggunakan sensor untuk mengukur jarak dan mendeteksi objek dengan cahaya laser, membantu mengklasifikasikan kematangan FFB berdasarkan bentuk dan ukuran dengan persentase 2%. *Hyperspectral Camera* menangkap spektrum cahaya yang luas, memungkinkan analisis lebih rinci dari komposisi buah, dengan persentase 2%. *Laser-Light Backscattering* menggunakan pantulan cahaya laser untuk mengukur sifat optik FFB, menentukan tingkat kematangan berdasarkan perubahan fisik dalam struktur buah dengan persentase 2%. Terakhir, metode *Fruit Battery* memanfaatkan reaksi kimia dalam buah yang berbeda tingkat kematangannya untuk klasifikasi kematangan, dengan persentase 2%. Keseluruhan variasi metode ini menunjukkan pendekatan yang komprehensif dan beragam dalam penelitian klasifikasi kematangan tandan buah segar kelapa sawit.

Tabel 3. Jenis Data Sampel yang Digunakan pada Setiap Metode

Metode	Tipe Dataset	Referensi	Persentase
Raman spectra	Buah Kelapa Sawit	[J16],[J18], [J28]	6%
Thermal imaging	Tandan Buah Segar Kelapa Sawit	[J20], [J21], [J22]	6%
Colour vision	Tandan Buah Segar Kelapa Sawit Buah Kelapa Sawit	[J23], [J25], [J29],[J31], [J32], [J33], [J34], [J35]	16%
LiDAR sensor	Tandan Buah Segar Kelapa Sawit	[J26]	2%
Hyperspectral camera	Tandan Buah Segar Kelapa Sawit	[J30]	2%
Laser-light backscattering	Tandan Buah Segar Kelapa Sawit	[J34]	2%
Fruit battery	Buah Kelapa Sawit	[J33]	2%

RQ2 : Algoritma/Model yang Paling Umum Diterapkan

Algoritma yang paling umum digunakan adalah Artificial Neural Network (ANN), yang diterapkan dalam 16% dari total jurnal. Convolutional Neural Network (CNN) juga populer, digunakan dalam 10% jurnal. Metode lain seperti K-Nearest Neighbors (KNN) dan MobileNetV2 masing-masing digunakan dalam 8% jurnal. Algoritma HSV diterapkan dalam 6% jurnal, sementara YOLOv4 digunakan dalam 4% jurnal. Beberapa algoritma lain yang diterapkan termasuk YOLOv8, YOLOv4-tiny, R-CNN, YOLOv5, SVM, ResNet, DenseNet, NASNet, EfficientNet, Weighted KNN, Trilayered Neural Network, LDA, MDA, Linear Regression, EfficientNetB0, dan YOLOv3, masing-masing dengan persentase penggunaan yang bervariasi antara 2% hingga 6%. Beragamnya algoritma yang digunakan menunjukkan pendekatan yang beragam dalam upaya meningkatkan akurasi dan efisiensi klasifikasi kematangan tandan buah segar kelapa sawit.

Tabel 4. Algoritma yang Diterapkan

Algoritma	Total	Referensi	Persentase
YOLOv8	50	[J1]	2,0%
k-nearest neighbor (k-NN)	1	[J2]	2,0%
HSV	3	[J2], [J6], [J30]	6,0%
YOLOv4	2	[J3], [J13]	4,0%
CNN	5	[J5], [J9], [J19], [J23], [J29]	10,0%
KNN	4	[J4], [J14], [J20], [J28]	8,0%
ANN	8	[J7], [J14], [J16], [J20], [J21], [J24], [J32], [J35]	16,0%
YOLOv4-tiny	1	[J8]	2,0%
R-CNN	1	[J10]	2,0%
MobileNetV2	4	[J11], [J15], [J17], [J19]	8,0%
YOLOv5	2	[J12], [J17]	4,0%
SVM	2	[J14], [J33]	4,0%
ResNet	2	[J15], [J31]	4,0%
DenseNet	2	[J15], [J31]	4,0%
NASNet	1	[J15]	2,0%
EfficientNet	3	[J15], [J17], [J23]	6,0%
Weighted KNN, Trilayered neural network	1	[J18]	2,0%
LDA	2	[J20], [J25]	4,0%
MDA	1	[J20]	2,0%
Linear regression	1	[J22]	2,0%
EfficientNetB0	1	[J27]	2,0%
Yolov3	1	[J29]	2,0%

RQ3 : Lokasi Pengambilan Dataset

Dataset yang digunakan dalam penelitian klasifikasi kematangan tandan buah segar kelapa sawit (FFB) dan buah kelapa sawit diambil dari berbagai lokasi untuk memastikan data yang komprehensif dan representatif. Sebanyak 13 dataset diambil langsung dari perkebunan kelapa sawit, memungkinkan peneliti untuk mendapatkan data yang realistis dan sesuai dengan kondisi lapangan. Selain itu, 2 dataset diakses dari sumber online seperti ROBOFLOW, yang mempermudah peneliti dalam mengakses data yang sudah ada. Tiga dataset dikumpulkan dari pabrik kelapa sawit, yang membantu peneliti memahami proses industri dan bagaimana kematangan buah mempengaruhi kualitas produksi minyak kelapa sawit. Terakhir, 11 dataset diambil dari laboratorium, yang memungkinkan kontrol yang lebih baik terhadap variabel yang dapat mempengaruhi hasil penelitian dan melakukan pengujian yang lebih mendalam dengan peralatan khusus. Dengan variasi lokasi pengambilan dataset ini, penelitian klasifikasi kematangan tandan buah segar kelapa sawit menjadi lebih menyeluruh dan mencakup berbagai kondisi lapangan dan laboratorium yang berbeda.

Tabel 5. Lokasi Pengambilan Dataset

Lokasi	Total	Referensi
perkebunan kelapa sawit	13	[J1], [J2], [J4], [J6], [J7], [J9], [J12], [J14], [J17], [J19], [J24], [J27], [J32]
ROBOFLOW, Internet	2	[J5], [J11]
pabrik kelapa sawit	3	[J3], [J8], [J13]
Laboratorium	11	[J15], [J16], [J18], [J20], [J21], [J22], [J26], [J28], [J33], [J34], [J35]

RQ4 : Metode Pengukuran Hasil Klasifikasi

Berbagai algoritma dan metrik digunakan untuk mengukur performa klasifikasi kematangan tandan buah segar kelapa sawit (FFB). Akurasi adalah metrik yang paling umum digunakan, diterapkan dalam 40% dari total jurnal. *Precision*, *Recall*, dan *F1-Score* juga banyak digunakan, mencapai 38% dari jurnal, menunjukkan pentingnya keseimbangan antara presisi dan kemampuan model untuk mendeteksi semua kasus positif. *Confusion matrix* digunakan dalam 36% jurnal, menyediakan detail tentang kinerja model pada tingkat klasifikasi yang lebih rinci. *Mean Average Precision* (mAP) digunakan dalam 16% jurnal, terutama dalam konteks evaluasi deteksi objek.

Intersection over Union (IoU) adalah metrik lain yang signifikan, digunakan dalam 8% jurnal untuk mengevaluasi seberapa baik prediksi objek tumpang tindih dengan kebenaran *ground truth*. *Anova Test* digunakan dalam 6% jurnal untuk analisis statistik variasi antara kelompok data. *Area Under the Curve* (AUC) digunakan dalam 4% jurnal untuk mengukur kemampuan model dalam membedakan antara kelas positif dan negatif. Selain itu, metrik seperti Post-hoc Tests (LSD dan Tukey HSD), *Mean Square Error* (MSE), *Cross-Entropy Error*, *Validation Accuracy* dan Loss, *Return Intensity Value*, dan *k-fold cross-validation* juga digunakan, meskipun dalam persentase yang lebih kecil. Variasi dalam penggunaan metrik ini menunjukkan pendekatan yang beragam dan komprehensif dalam mengevaluasi kinerja model klasifikasi kematangan FFB, memberikan gambaran yang lebih lengkap dan mendalam tentang efektivitas metode yang diterapkan.

Tabel 5. Metode Pengukuran Hasil Klasifikasi

Metode	Total	Referensi	Presentase
<i>Intersection over Union</i> (IoU)	4	[J1], [J3], [J10], [J13]	8,00%
<i>Precision, Recall, and F1-Score</i>	19	[J1], [J3], [J5], [J6], [J7], [J8], [J9], [J10], [J11], [J12], [J13], [J14], [J15], [J17], [J19], [J27], [J29], [J31], [J32]	38,00%
<i>Mean Average Precision</i> (mAP)	8	[J1], [J3], [J8], [J10], [J12], [J13], [J17], [J29]	16,00%

<i>confusion matrix</i>	18	[J2], [J5], [J6], [J7], [J8], [J9], [J10], [J11], [J13], [J15], [J16], [J17], [J19], [J20], [J25], [J29], [J31], [J32]	36,00%
Akurasi	20	[J5], [J6], [J7], [J9], [J11], [J12], [J14], [J15], [J16], [J19], [J20], [J21], [J25], [J27], [J28], [J31], [J32], [J33], [J34], [J35]	40,00%
<i>k-fold cross-validation</i>	1	[J4]	2,00%
<i>Validation Accuracy dan Loss</i>	1	[J11]	2,00%
<i>Area Under the Curve (AUC)</i>	2	[J14], [J15]	4,00%
<i>Mean Square Error (MSE)</i>	1	[J14]	2,00%
<i>Cross-Entropy Error</i>	1	[J16]	2,00%
<i>Anova Test</i>	3	[J20], [J28], [J34]	6,00%
<i>Post-hoc Tests (LSD and Tukey HSD)</i>	2	[J20], [J28]	4,00%
<i>Return Intensity Value</i>	1	[J26]	2,00%

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan kajian literatur sistematis yang telah dilakukan, terlihat bahwa klasifikasi kematangan tandan buah segar kelapa sawit (FFB) menggunakan teknologi deep learning menunjukkan hasil yang sangat menjanjikan. Penggunaan berbagai algoritma seperti *Artificial Neural Network* (ANN), *Convolutional Neural Network* (CNN), *K-Nearest Neighbors* (KNN), dan *MobileNetV2* menunjukkan kemampuan yang tinggi dalam mengklasifikasikan tingkat kematangan buah kelapa sawit dengan akurasi yang bervariasi namun cukup tinggi. Algoritma ANN adalah yang paling banyak digunakan dengan persentase 16%, diikuti oleh CNN dengan 10%.

Berbagai metode pengukuran hasil klasifikasi juga telah diterapkan, dengan akurasi menjadi metrik yang paling umum digunakan dalam 40% jurnal. Precision, Recall, dan F1-Score juga banyak digunakan untuk mengevaluasi performa model dengan persentase 38%. Metode seperti *Confusion Matrix*, *Mean Average Precision* (mAP), dan *Intersection over Union* (IoU) juga sering digunakan untuk memberikan gambaran yang lebih detail tentang kinerja model.

Dataset yang digunakan dalam penelitian-penelitian ini diambil dari berbagai lokasi untuk memastikan data yang representatif, termasuk perkebunan kelapa sawit, pabrik kelapa sawit, laboratorium, dan sumber *online* seperti ROBOFLOW. Variasi lokasi ini memberikan data yang komprehensif dan realistis, yang penting untuk pengembangan model *deep learning* yang akurat dan efisien.

Saran

Untuk implementasi praktis, industri kelapa sawit perlu meningkatkan infrastruktur teknologi mereka untuk mendukung penerapan model *deep learning* secara efektif. Ini termasuk investasi dalam perangkat keras yang memadai dan pelatihan bagi tenaga kerja untuk memastikan kemampuan mereka dalam mengoperasikan dan memelihara sistem baru. Selain itu, diperlukan kolaborasi yang lebih erat antara industri dan akademisi untuk memastikan bahwa teknologi yang dikembangkan sesuai dengan kebutuhan industri dan dapat diimplementasikan secara praktis. Dalam pengembangan teori, diperlukan penelitian lanjutan untuk meningkatkan generalisasi model *deep learning*. Peneliti dapat fokus pada pengembangan model yang lebih mampu beradaptasi dengan variasi data yang lebih luas. Penelitian lebih lanjut juga dapat mengintegrasikan data dari berbagai sumber seperti citra RGB, citra termal, dan spektrum Raman untuk meningkatkan akurasi klasifikasi. Untuk penelitian lanjutan, uji lapangan lebih lanjut perlu dilakukan untuk menguji keefektifan model dalam kondisi nyata di perkebunan dan pabrik kelapa sawit. Pengumpulan dataset yang lebih besar dan lebih beragam juga sangat membantu dalam meningkatkan performa dan keandalan model *deep learning*. Dengan adanya peningkatan teknologi dan kolaborasi yang baik antara berbagai pihak, diharapkan bahwa klasifikasi

kematangan tandan buah segar kelapa sawit menggunakan *deep learning* dapat diimplementasikan secara luas, meningkatkan efisiensi dan kualitas produksi minyak kelapa sawit.

UCAPAN TERIMA KASIH

Penulis ingin mengucapkan terima kasih kepada Prof. Dr. Kusrini, M.Kom yang telah memberikan bimbingan, dukungan, dan pengetahuan berharga selama proses pembuatan jurnal ini. Penulis juga ingin menyampaikan terima kasih kepada suami yang telah mendukung selama proses pengerjaan jurnal ini. Terima kasih juga penulis sampaikan kepada seluruh keluarga yang selalu memberikan doa.

REFERENSI

- Alfatni, M. S. M., Mohamed Shariff, A. R., Ben Saaed, O. M., & Albhbah, A. M., & Mustapha, A. (2020). Colour feature extraction methods for real-time system of oil palm fresh fruit bunch maturity grading. *IOP Conference Series: Earth and Environmental Science*, 540, 012092.
- Aliteh, N. A., Minakata, K., Tashiro, K., Wakiwaka, H., Kobayashi, K., Nagata, H., & Misron, N. (2020). Fruit battery method for oil palm fruit ripeness sensor and comparison with computer vision method. *Sensors*, 20, 637.
- Azmi, M. H. I. M., Hashim, F. H., Huddin, A. B., & Sajab, M. S. (2022). Correlation study between the organic compounds and ripening stages of oil palm fruitlets based on the Raman spectra. *Sensors*, 22, 7091.
- Bonet, I., Gongora, M., Acevedo, F., & Ochoa, I. (2024). Deep learning model to predict the ripeness of oil palm fruit. In *Proceedings of the 16th International Conference on Agents and Artificial Intelligence (ICAART 2024)* (Vol. 3, pp. 1068-1075). SCITEPRESS – Science and Technology Publications, Lda. <https://doi.org/10.5220/0012434600003636>
- Databoks. (2024, Juni 6). Luas perkebunan sawit Indonesia tumbuh 56% dalam sedekade. Katadata. Diakses pada 16 Juni 2024, dari <https://databoks.katadata.co.id/datapublish/2024/06/06/luas-perkebunan-sawit-indonesia-tumbuh-56-dalam-sedekade>
- Fauziah, W. K., Makky, M., Santosa, & Cherie, D. (2021). Thermal vision of oil palm fruits under different ripeness quality. *IOP Conference Series: Earth and Environmental Science*, 644, 012044.
- Herman, H., Susanto, A., Cenggoro, T. W., Suharjito, & Pardamean, B. (2020). Oil palm fruit image ripeness classification with computer vision using deep learning and visual attention. *Journal of Telecommunications and the Digital Economy*, 12, 21–27.
- Husin, H. S., Amar, N., Bakar Sajak, A. A., & Sallehin Mohd Kassim, M. (2021). Distribution map of oil palm fresh fruit bunch using LiDAR. In *Proceedings of the 2021 12th International Conference on Information and Communication Systems (ICICS)* (pp. 4–9). Valencia, Spain.
- Junos, M. H., Mohd Khairuddin, A. S., Thannirmalai, S., & Dahari, M. (2021). An optimized YOLO-based object detection model for crop harvesting system. *IET Image Processing*, 15, 2112–2125.
- Makky, M., & Cherie, D. (2021). Pre-harvest oil palm FFB nondestructive evaluation method using thermal-imaging device. *IOP Conference Series: Earth and Environmental Science*, 757, 012003.
- Mohd Ali, M., Hashim, N., & Abdul Hamid, A. S. (2020). Combination of laser-light backscattering imaging and computer vision for rapid determination of oil palm fresh fruit bunches maturity. *Computers and Electronics in Agriculture*, 169, 105235.
- Pusadan, M. Y., Safitri, I., & Wirdayanti. (2023). The image extraction using the HSV method to determine the maturity level of palm oil fruit with the k-nearest neighbor algorithm. *JURNAL RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 7(6), 1448-1456. <http://jurnal.iaii.or.id>

- 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, 18315.
- Saifullah, S., Prasetyo, D. B., Indahyani, I., Drezewski, R., & Dwiyanto, F. A. (2023). Palm oil maturity classification using K-nearest neighbors based on RGB and Lab color extraction. In *Procedia Computer Science*, 225, 3011-3020. <https://doi.org/10.1016/j.procs.2023.09.008>
- Septiarini, A., Hatta, H. R., Hamdani, H., Oktavia, A., Kasim, A. A., & Suyanto, S. (2020). Maturity grading of oil palm fresh fruit bunches based on a machine learning approach. In *Proceedings of the 2020 5th International Conference on Informatics and Computing (ICIC)* (pp. 19–22). Gorontalo, Indonesia.
- 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. *Scientific Horticulture*, 286, 110245.
- Setiawan, A. W., & Prasetya, O. E. (2020). Palm oil fresh fruit bunch grading system using multispectral image analysis in HSV. In *Proceedings of the 2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT)* (pp. 85–88). Doha, Qatar.
- Suharjito, Asrol, M., Utama, D. N., Junior, F. A., & Marimin. (2023). Real-time oil palm fruit grading system using smartphone and modified YOLOv4. *IEEE Access*, 10, 3285537. <https://doi.org/10.1109/ACCESS.2023.3285537>
- 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, 106359.
- Tzuan, G. T. H., Hashim, F. H., Raj, T., Huddin, A. B., & Sajab, M. S. (2022). Oil palm fruits ripeness classification based on the characteristics of protein, lipid, carotene, and guanine/cytosine from the Raman spectra. *Plants*, 11, 1936.
- Zolfagharnassab, S., Shariff, A. R. B. M., Ehsani, R., Jaafar, H. Z., & Aris, I. B. (2022). Classification of oil palm fresh fruit bunches based on their maturity using thermal imaging techniques. *Agriculture*, 12, 1779.
- Zamri, N. M., & Anuar, A. K. (2023). Palm fresh fruit bunches (FFBs) colour grading system using Raspberry Pi. *Evolution in Electrical and Electronic Engineering*, 4(2), 574-581. <https://doi.org/10.30880/eeee.2023.04.02.070>
- Wang, H. H., Wang, Y. C., Wee, B. L., & Sim, S. W. (2024). Novel feature extraction for oil palm bunches classification. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 34(1), 350-360. https://semarakilmu.com.my/journals/index.php/applied_sciences_eng_tech/index
- Shiddiq, M., Candra, F., Anand, B., & Rabin, M. F. (2024). Neural network with k-fold cross validation for oil palm fruit ripeness prediction. *TELKOMNIKA Telecommunication Computing Electronics and Control*, 22(1), 164-174. <https://doi.org/10.12928/TELKOMNIKA.v22i1.24845>
- Salim, E., & Suharjito. (2023). Hyperparameter optimization of YOLOv4 tiny for palm oil fresh fruit bunches maturity detection using genetics algorithms. *Smart Agricultural Technology*, 6, 100364. <https://doi.org/10.1016/j.atech.2023.100364>
- Azman, H., & Suriani, N. S. (2023). Grading oil palm fruit bunch using convolution neural network. *Evolution in Electrical and Electronic Engineering*, 4(1), 185-194. <https://doi.org/10.30880/eeee.2023.04.01.022>
- Siricharoen, P., Yomsatieankul, W., & Bunsri, T. (2023). Fruit maturity grading framework for small dataset using single image multi-object sampling and Mask R-CNN. *Smart Agricultural Technology*, 3, 100130. <https://doi.org/10.1016/j.atech.2023.100130>
- Gulzar, Y. (2023). Fruit image classification model based on MobileNetV2 with deep transfer learning technique. *Journal of Agricultural Technology*, 12(1), 99-110. <https://doi.org/10.1016/j.jatech.2023.100112>

- Mamat, N., Othman, M. F., Abdulghafor, R., & Alwan, A. A., & Gulzar, Y. (2023). Enhancing image annotation technique of fruit classification using a deep learning approach. *Journal of Agricultural Technology*, 12(1), 120-132. <https://doi.org/10.1016/j.jatech.2023.100120>
- Suharjito, Junior, F. A., Koeswandy, Y. P., Nurhayati, P. W., Asrol, M., & Marimin. (2023). Annotated datasets of oil palm fruit bunch piles for ripeness grading using deep learning. *Journal of Agricultural Technology*, 12(1), 54-67. <https://doi.org/10.1016/j.jatech.2023.100054>
- Alfatni, M. S. M., Khairunniza-Bejo, S., Marhaban, M. H. B., Ben Saaed, O. M., Mustapha, A., & Mohamed Shariff, A. R. (2022). Towards a real-time oil palm fruit maturity system using supervised classifiers based on feature analysis. *Journal of Agricultural Technology*, 11(1), 33-45. <https://doi.org/10.1016/j.jatech.2022.100033>
- Ismail, N., & Malik, O. A. (2022). Real-time visual inspection system for grading fruits using computer vision and deep learning techniques. *Information Processing in Agriculture*, 9, 24-37. <https://doi.org/10.1016/j.inpa.2022.100024>
- Tzuan, G. T. H., Hashim, F. H., Raj, T., Huddin, A. B., & Sajab, M. S. (2022). Oil palm fruits ripeness classification based on the characteristics of protein, lipid, carotene, and guanine/cytosine from the Raman spectra. *Information Processing in Agriculture*, 9(3), 24-37. <https://doi.org/10.1016/j.inpa.2022.100024>
- Mansour, M. Y. M. A., Dambul, K. D., & Choo, K. Y. (2022). Object detection algorithms for ripeness classification of oil palm fresh fruit bunch. *International Journal of Technology*, 13(6), 1326-1335. <http://ijtech.eng.ui.ac.id>
- Luddin, M. H. M., & Rahman, M. A. (2022). Comparison CNN and MobileNet_v2 model for oil palm FBB ripeness classification. *Evolution in Electrical and Electronic Engineering*, 3(2), 146-154. <https://doi.org/10.30880/eeee.2022.03.02.018>
- Melidawati, et al. (2021). Non-destructive evaluation quality of oil palm fresh fruit bunch (FFB) (*Elaeis guineensis* Jack) based on optical properties using artificial neural network (ANN). *IOP Conference Series: Earth and Environmental Science*, 644, 012032. <https://doi.org/10.1088/1755-1315/644/1/012032>
- Teh, W. Y., & Tan, I. K. T. (2021). Coloured edge maps for oil palm ripeness classification. *Journal of Agricultural Technology*, 11(2), 78-89.