

OPTIMASI MODEL PENGKLASIFIKASI BIBIT KELAPA LOKAL DENGAN ALGORITMA DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK

¹Muhammad Jibril, ²Achmad Isya Alfassa

^{1,2} Universitas Islam Indragiri (UNISI)

Jl. Provinsi No. 01 Tembilahan Hulu, Indragiri Hilir, Riau - Indonesia

Email: muhammadjibril@unisi.ac.id

ABSTRAK

Klasifikasi bibit kelapa lokal masih mengandalkan metode manual yang subjektif dan tidak konsisten. Penelitian ini mengembangkan model Convolutional Neural Network (CNN) yang dioptimasi untuk klasifikasi empat kelas kualitas bibit: Premium, Standard, Low, dan Rejected. Dataset berisi 4.004 citra, dengan augmentasi dan stratified splitting untuk menjaga distribusi kelas. Model terdiri dari tiga blok konvolusi dengan batch normalization, max-pooling, dropout, dan fully connected layer, berjumlah 495.108 parameter terlatih. Optimasi dilakukan melalui fine-tuning, hyperparameter tuning, dan regularisasi. Hasil menunjukkan akurasi 96%, precision, recall, dan F1-score tinggi, serta ROC-AUC mendekati 1.00 untuk semua kelas, menandakan kemampuan klasifikasi yang akurat dan generalisasi baik. Model ini efisien secara komputasi, siap diterapkan di lapangan untuk mendukung peningkatan kualitas bibit kelapa lokal.

Kata Kunci: Deep Learning; Convolutional Neural Network; Bibit Kelapa Lokal; Klasifikasi; Pertanian Cerdas.

1 PENDAHULUAN

Kelapa merupakan salah satu komoditas strategis yang berperan penting dalam mendukung sektor pertanian dan perekonomian Indonesia. Kualitas bibit kelapa menjadi faktor utama yang menentukan produktivitas tanaman, mulai dari ketahanan terhadap hama hingga hasil panen yang optimal. Di Kabupaten Indragiri Hilir, Riau, kelapa lokal menjadi komoditas unggulan masyarakat pesisir. Data menunjukkan bahwa luas lahan perkebunan kelapa mencapai 341.722 Ha pada tahun 2022 dan sedikit menurun menjadi 340.941 Ha pada tahun 2023 [1]. Penurunan luas lahan ini juga diikuti oleh penurunan produksi, dari 313.430 ton pada tahun 2022 menjadi 307.768 ton pada tahun 2023, dengan kondisi tanaman tua dan rusak mencapai 100.285 Ha [2]. Kondisi tersebut menunjukkan bahwa peremajaan dan perbaikan kualitas bibit menjadi kebutuhan mendesak.

Sebagai komoditas utama, kelapa lokal tidak hanya berkontribusi terhadap perekonomian daerah tetapi juga menopang kehidupan masyarakat melalui pemanfaatan hasilnya sebagai bahan pangan, energi, bahan baku industri, hingga sumber pendapatan utama bagi petani [3]. Oleh karena itu, klasifikasi dan seleksi bibit kelapa lokal memiliki peran penting dalam menjaga kualitas, keragaman genetik, dan keberlanjutan produksi. Namun, hingga saat ini proses seleksi bibit masih banyak mengandalkan metode konvensional berbasis pengamatan manual. Metode tersebut bersifat subjektif, tidak konsisten, dan memerlukan waktu serta tenaga yang tidak sedikit. Hal ini menyebabkan hasil seleksi seringkali tidak optimal.

Di sisi lain, perkembangan teknologi digital dalam bidang pertanian telah membuka peluang baru, terutama dengan hadirnya deep learning [4]. Salah satu pendekatan yang banyak digunakan adalah Convolutional Neural Network (CNN), yang terbukti efektif dalam klasifikasi citra, termasuk pada bidang pertanian seperti klasifikasi tanaman dan deteksi penyakit [5]. Berbagai penelitian terkini menunjukkan potensi CNN dalam mendukung sistem pertanian cerdas, misalnya pada deteksi kematangan buah, klasifikasi varietas, hingga identifikasi penyakit tanaman. Meskipun demikian, implementasi CNN secara khusus untuk klasifikasi bibit kelapa masih terbatas. Tantangan yang muncul adalah bagaimana merancang model yang tidak hanya akurat tetapi juga efisien secara komputasi sehingga dapat diterapkan pada perangkat dengan spesifikasi terbatas yang umum digunakan oleh petani.

Berdasarkan kondisi tersebut, penelitian ini berfokus pada pengembangan dan optimasi model CNN untuk klasifikasi bibit kelapa lokal. Penelitian ini menghadirkan kebaruan dalam empat aspek utama: (1) pengembangan model CNN yang secara spesifik ditujukan untuk klasifikasi bibit kelapa lokal, sebuah komoditas penting yang belum banyak diteliti dalam konteks deep learning; (2) penerapan strategi optimasi komprehensif melalui fine-tuning, augmentasi data, dan hyperparameter tuning untuk meningkatkan akurasi sekaligus menjaga efisiensi komputasi; (3) integrasi teknik regularisasi modern seperti dropout dan batch normalization guna mengurangi overfitting; serta (4) perancangan model yang siap diterapkan di lapangan dengan dukungan pada perangkat berspesifikasi terbatas. Dengan demikian, penelitian ini tidak hanya mengisi kesenjangan ilmiah, tetapi juga memberikan kontribusi praktis dalam mendukung transformasi pertanian menuju smart agriculture.

2 LITERATUR REVIEW

Penelitian mengenai penerapan CNN dan metode machine learning lain pada klasifikasi citra pertanian, termasuk komoditas kelapa, telah dilakukan dalam berbagai konteks. CNN, misalnya, digunakan dalam klasifikasi tingkat kematangan kelapa dengan pendekatan Mask R-CNN dan IFDM [7], klasifikasi varietas kelapa lokal [4], klasifikasi bibit kelapa [8], serta deteksi penyakit dan infeksi hama pada pohon kelapa [9]. Model VGG-16 dan Custom DCNN juga telah diterapkan untuk mendeteksi serangan whitefly [10],[11], sementara penelitian lain memanfaatkan CNN untuk mendeteksi penyakit pada pohon kelapa [12].


Selain CNN, berbagai metode machine learning klasik juga pernah diterapkan. Nearest Mean Classifier (NMC) digunakan untuk klasifikasi bibit kelapa dengan rata-rata ketelitian 87,02% [3] serta untuk deteksi hama dan penyakit kelapa dengan akurasi 89,87% [13]. Naive Bayes Classifier (NBC) juga digunakan dalam klasifikasi bibit kelapa dengan rata-rata ketelitian serupa, yaitu 87,02% [14]. Penelitian lainnya memanfaatkan ResNet50 dalam klasifikasi penyakit daun kelapa [5], DeeplabV3+ untuk segmentasi organ kelapa [15], serta MIN-SVM dalam klasifikasi pohon kelapa berdasarkan parameter morfologi [16]. Model modern lain seperti Custom 2D-CNN, InceptionResNetV2, dan MobileNet juga telah digunakan untuk deteksi penyakit dan infeksi hama pada pohon kelapa [9]. Bahkan Artificial Neural Network (ANN) [17] dan Case-Based Reasoning (CBR) [18] juga pernah digunakan pada kasus terkait kelapa.

Untuk meningkatkan kinerja model, berbagai pendekatan optimasi telah dikembangkan. Fine-tuning terbukti efektif dalam meningkatkan performa model [19], sedangkan augmentasi data digunakan untuk memperluas keragaman dataset dan mencegah overfitting [20,21]. Hyperparameter tuning juga banyak digunakan, termasuk kombinasi dengan SVM [20,22,23], maupun pendekatan berbasis algoritma optimasi seperti improved salp swarm optimization [24]. Selain itu, penggunaan model pre-trained [25] memberikan keuntungan dalam mempercepat proses pelatihan dan meningkatkan akurasi. Penelitian terbaru juga menyoroti pentingnya lightweight attention untuk mengurangi kompleksitas model [26] serta adaptive feature selection yang dapat meningkatkan efisiensi CNN [27].

Dari berbagai penelitian terdahulu tersebut dapat disimpulkan bahwa CNN memiliki potensi besar dalam klasifikasi citra kelapa, baik dalam hal kematangan, penyakit, maupun klasifikasi bibit. Namun, sebagian besar model masih berfokus pada buah dan penyakit, sedangkan penelitian yang secara khusus mengoptimalkan CNN untuk klasifikasi bibit kelapa lokal masih sangat terbatas. Selain itu, model yang ada umumnya berorientasi pada akurasi tinggi tetapi masih membutuhkan komputasi berat sehingga kurang sesuai untuk aplikasi di lapangan. Oleh karena itu, penelitian ini mengisi kesenjangan tersebut dengan mengembangkan model CNN yang tidak hanya akurat tetapi juga ringan dan efisien, sehingga dapat diterapkan secara langsung untuk membantu petani dalam meningkatkan kualitas bibit kelapa lokal.


3 METODE

Penelitian ini berfokus pada optimasi model Convolutional Neural Network (CNN) untuk meningkatkan akurasi klasifikasi bibit kelapa lokal. Tahapan penelitian dibagi menjadi empat langkah utama. Pertama, pengumpulan dan preprocessing data, yaitu mengumpulkan dataset citra bibit kelapa, melakukan anotasi manual, serta menerapkan augmentasi dan normalisasi data. Langkah ini bertujuan untuk memperkaya variasi citra sekaligus meningkatkan ketahanan model terhadap kondisi data yang beragam. Kedua, pengembangan dan optimasi model CNN, yang mencakup pemilihan arsitektur CNN yang sesuai, penerapan teknik fine-tuning pada struktur model, hyperparameter tuning, serta penggunaan metode regularisasi modern seperti dropout dan batch normalization guna mengurangi risiko overfitting. Ketiga, evaluasi model, di mana performa CNN diukur menggunakan metrik akurasi, presisi, recall, dan F1-score. Evaluasi dilakukan dengan membandingkan hasil model yang dioptimalkan dengan model baseline serta menggunakan validasi silang untuk menjamin kemampuan generalisasi. Keempat, implementasi dan integrasi, yaitu merancang model agar efisien dan siap diterapkan di lapangan, termasuk pada perangkat dengan spesifikasi terbatas, sehingga dapat digunakan secara praktis oleh petani maupun industri.



Gambar 1. Diagram Alir Penelitian

CNN juga terdiri dari banyak neuron yang memiliki weight, bias, dan activation function. Tahapan-tahapan algoritma CNN disajikan dalam bentuk gambar sebagaimana berikut.



Gambar 2. Arsitektur CNN

4 HASIL DAN PEMBAHASAN


Dataset penelitian ini terdiri dari citra bibit kelapa lokal yang telah melalui quality control. Seluruh citra dikelompokkan menjadi empat kelas, yaitu A (Premium), B (Standard), C (Low), dan D (Rejected). Dataset dibagi menjadi tiga subset: training, validation, dan testing, dengan distribusi kelas yang dijaga seimbang melalui metode stratified splitting. Jumlah total citra pada masing-masing subset adalah 3.206 untuk training, 399 untuk validation, dan 399 untuk testing. Proses augmentasi diterapkan pada dataset training untuk meningkatkan variasi citra dan memperkuat kemampuan generalisasi model. Teknik augmentasi yang digunakan meliputi random resized crop, rotasi, flipping horizontal dan vertikal, affine transform, color jitter, serta penambahan gaussian noise. Augmentasi ini membantu model CNN mengekstrak fitur yang lebih relevan dari berbagai kondisi nyata, sehingga diharapkan meningkatkan akurasi klasifikasi setiap kelas bibit.



Gambar 3. Sampel Bibit Kelapa

Gambar 4 menampilkan delapan contoh augmentasi yang diterapkan pada satu citra bibit kelapa. Augmentasi ini bertujuan meningkatkan keragaman dataset sehingga model Convolutional Neural Network (CNN) dapat mempelajari fitur yang lebih general dan mengurangi risiko overfitting pada pola tertentu. Beberapa jenis augmentasi yang terlihat antara lain rotasi citra dengan sudut berbeda untuk mensimulasikan variasi orientasi tanaman, pemantulan vertikal agar model tetap mengenali bibit meskipun posisinya terbalik, serta translasi atau perubahan sudut pandang dengan latar belakang hitam di pojok citra untuk meniru pergeseran posisi kamera. Selain

itu, terdapat transformasi warna dan peningkatan saturasi untuk meniru variasi pencahayaan atau kualitas kamera, serta peningkatan kecerahan atau efek pudar untuk mensimulasikan kondisi cahaya berbeda di lapangan. Implementasi augmentasi ini memungkinkan peningkatan keragaman data latih tanpa menambah jumlah sampel asli, sehingga model menjadi lebih robust terhadap perubahan kondisi nyata seperti orientasi, pencahayaan, atau posisi tanaman. Dengan pendekatan ini, diharapkan akurasi klasifikasi bibit premium, standar, dan rendah meningkat karena model mampu mengekstrak fitur yang lebih relevan dari berbagai kondisi.



Gambar 4. Augmentasi Data


Arsitektur model CNN yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1. Model terdiri dari tiga blok konvolusi berturut-turut, masing-masing diikuti dengan batch normalization dan max-pooling. Blok pertama menggunakan lapisan konvolusi dengan 32 filter berukuran 3×3 , yang menghasilkan feature map berukuran 224×224 . Lapisan ini diikuti oleh batch normalization untuk menstabilkan distribusi aktivasi serta max-pooling yang mengurangi dimensi spasial menjadi 112×112 . Blok kedua menggunakan 64 filter konvolusi dengan ukuran kernel yang sama, dilanjutkan dengan batch normalization dan max-pooling sehingga ukuran feature map berkurang menjadi 56×56 . Pada blok ketiga, jumlah filter ditingkatkan menjadi 128, dengan output feature map berukuran 28×28 setelah proses pooling. Setelah ketiga blok konvolusi, hasil ekstraksi fitur diratakan (flatten) menjadi vektor berdimensi 100.352, kemudian melalui lapisan dropout dengan probabilitas 0.5 untuk mencegah overfitting. Selanjutnya, vektor masukan diproses oleh lapisan fully connected (linear layer) dengan 5 neuron output sesuai jumlah kelas yang digunakan dalam penelitian ini.

Tabel 1. Arsitektur Model

Layer (Type)	Output Shape	Param #
Conv2d-1	[-1, 32, 224, 224]	896
BatchNorm2d-2	[-1, 32, 224, 224]	64
MaxPool2d-3	[-1, 32, 112, 112]	0
Dropout-4	[-1, 32, 112, 112]	0
Conv2d-5	[-1, 64, 112, 112]	18,496
BatchNorm2d-6	[-1, 64, 112, 112]	128
MaxPool2d-7	[-1, 64, 56, 56]	0
Dropout-8	[-1, 64, 56, 56]	0
Conv2d-9	[-1, 128, 56, 56]	73,856
BatchNorm2d-10	[-1, 128, 56, 56]	256
MaxPool2d-11	[-1, 128, 28, 28]	0
Dropout-12	[-1, 100352]	0
Linear-13	[-1, 4]	401,412
Total params		495,108
Trainable params		495,108
Non-trainable params		0


Secara keseluruhan, model memiliki 595.461 parameter terlatih (trainable parameters) dan tidak ada parameter non-trainable. Kompleksitas parameter yang relatif ringan membuat model ini efisien untuk dijalankan pada perangkat dengan sumber daya terbatas, tanpa mengurangi kemampuan generalisasi terhadap data validasi dan data uji.

Hasil pelatihan model yang digambarkan pada Gambar 5 menunjukkan kinerja CNN dalam proses klasifikasi. Kurva loss pelatihan dan validasi memperlihatkan pola penurunan yang konsisten sejak awal epoch. Nilai loss menurun secara signifikan pada fase awal pembelajaran dan kemudian mencapai kondisi stabil dalam kisaran rendah. Fenomena ini menunjukkan bahwa model mampu mempelajari pola representasi data dengan cepat sekaligus mempertahankan kestabilan tanpa adanya indikasi perbedaan mencolok antara kurva pelatihan dan validasi. Dengan demikian, proses pembelajaran dapat dikatakan berjalan efektif, di mana model tidak hanya menyesuaikan parameter terhadap data pelatihan, tetapi juga mampu menjaga performa pada data validasi. Kondisi ini mengindikasikan bahwa strategi optimasi yang diterapkan telah berhasil meningkatkan kemampuan generalisasi model, sehingga dapat diandalkan untuk menghadapi data uji maupun data baru di lapangan.



Gambar 5. Grafik Training dan Validation Model

Kurva Training vs Validation Loss dan Training vs Validation Accuracy selama 30 epoch (Gambar 5). Dari grafik Loss, terlihat bahwa nilai loss pada training dan validation menurun secara signifikan pada beberapa epoch awal dan kemudian stabil di kisaran yang rendah, menunjukkan model mengalami konvergensi dengan baik. Meskipun terdapat beberapa fluktuasi minor pada beberapa epoch, baik training maupun validation loss tetap rendah, menandakan minimnya overfitting. Pada grafik accuracy, training accuracy cenderung sedikit lebih tinggi daripada validation accuracy, yang merupakan pola yang umum pada model yang belajar dengan baik. Akurasi validation stabil di sekitar 96–97%, menandakan performa model yang konsisten pada data yang tidak terlihat selama training. Gambar 6 menunjukkan Confusion Matrix pada dataset uji. Dari matriks ini, dapat diamati bahwa model mampu mengklasifikasikan sebagian besar sampel dengan benar, terutama untuk kelas A (Premium) dan D (Rejected), di mana jumlah prediksi benar sangat tinggi. Beberapa kesalahan klasifikasi terjadi pada kelas B (Standard) dan C (Low), tetapi jumlahnya relatif kecil, sehingga dampak terhadap akurasi total tidak signifikan. Hal ini mendukung nilai F1-score, precision, dan recall yang tinggi pada tabel sebelumnya.


**Gambar 6. Confusion Matrix**

Tabel 2 menunjukkan performa klasifikasi model CNN pada dataset bibit kelapa lokal yang dibagi menjadi empat kelas kualitas. Secara keseluruhan, model berhasil mencapai akurasi sebesar 96%, dengan nilai precision, recall, dan F1-score yang tinggi, menunjukkan kemampuan klasifikasi yang seimbang antar kelas. Kelas A (Premium) memiliki precision 0.96 dan recall 0.99, menandakan sebagian besar prediksi kelas ini benar dan hampir semua sampel kelas A terdeteksi dengan tepat. Kelas B (Standard) menunjukkan precision 1.00 dan recall 0.95, mengindikasikan model tidak melakukan kesalahan pada prediksi kelas ini, meskipun beberapa sampel kelas B terklasifikasi ke kelas lain. Kelas C (Low) memiliki nilai precision 0.99 dan recall 0.94, yang menunjukkan efektivitas tinggi dalam prediksi, namun beberapa sampel kelas C tertukar ke kelas lain. Kelas D (Rejected) memiliki recall sempurna 1.00 tetapi precision lebih rendah 0.90, yang berarti semua sampel D berhasil terdeteksi, meskipun terdapat prediksi kelas lain yang salah masuk ke kelas D. Nilai macro average dan weighted average masing-masing mendekati 0.96–0.97, menegaskan bahwa performa model relatif seimbang antar kelas, baik untuk kelas dengan jumlah sampel besar maupun kecil. Hasil ini menandakan bahwa model CNN yang digunakan mampu membedakan kualitas bibit kelapa lokal secara efektif dengan sedikit bias pada kelas tertentu.

Tabel 2. Performa Klasifikasi Model

Kelas	Precision	Recall	F1-Score
A (Premium)	0.96	0.99	0.97
B (Standard)	1.00	0.95	0.97
C (Low)	0.99	0.94	0.97
D (Rejected)	0.90	1.00	0.95
Accuracy			0.96
Macro Avg	0.96	0.97	0.96
Weighted Avg	0.97	0.96	0.97

Gambar 7 menampilkan ROC Curve dan nilai AUC untuk masing-masing kelas. ROC curve untuk semua kelas berada dekat dengan sudut kiri atas, dan nilai AUC masing-masing kelas adalah 1.00, menunjukkan kemampuan model yang sangat baik dalam membedakan setiap kelas. Hal ini mengindikasikan bahwa model memiliki sensitivitas dan spesifisitas yang optimal dalam mengklasifikasikan setiap kategori.



Gambar 7. ROC & AUC Curve

Secara keseluruhan, kombinasi antara kurva training/validation, confusion matrix, dan ROC-AUC menunjukkan bahwa model CNN yang digunakan berhasil melakukan klasifikasi dengan akurasi tinggi, generalisasi yang baik, dan mampu membedakan kelas secara efektif, dengan risiko overfitting yang minimal.

5 KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa model Convolutional Neural Network (CNN) yang dioptimalkan mampu melakukan klasifikasi bibit kelapa lokal dengan akurasi tinggi dan generalisasi yang baik. Dataset yang telah melalui quality control dan diperkuat dengan augmentasi data memungkinkan model untuk mengekstrak fitur yang lebih relevan dari berbagai kondisi nyata, sehingga risiko overfitting dapat diminimalkan. Analisis performa model melalui kurva training dan validation, confusion matrix, serta ROC-AUC mengindikasikan bahwa model mampu membedakan kelas bibit secara efektif. Model menunjukkan akurasi keseluruhan sebesar 96%, dengan nilai precision, recall, dan F1-score yang tinggi untuk semua kelas. Kelas A (Premium) dan D (Rejected) berhasil diklasifikasikan dengan sangat baik, sementara kelas B (Standard) dan C (Low) memiliki sedikit kesalahan klasifikasi tetapi tetap mempertahankan performa yang seimbang. Nilai ROC-AUC mencapai 1.00 untuk setiap kelas, menegaskan sensitivitas dan spesifisitas optimal dari model. Secara keseluruhan, pendekatan optimasi CNN yang diterapkan meliputi augmentasi data, fine-tuning arsitektur, hyperparameter tuning, serta regularisasi dengan dropout dan batch normalization terbukti efektif untuk meningkatkan kemampuan klasifikasi bibit kelapa lokal. Model yang dihasilkan tidak hanya akurat tetapi juga efisien, sehingga siap diterapkan pada perangkat dengan spesifikasi terbatas untuk mendukung praktis penggunaan di lapangan.

REFERENSI

- [1] Badan Pusat Statistik Provinsi Riau. Provinsi Riau dalam angka 2024. Riau: BPS-Statistics Riau Province; 2024. Available from: <https://riau.bps.go.id/id/publication/2024/02/28/b75ed69ddf689a2e23f46207/provinsi-riau-dalam-angka-2024.html>.
- [2] Badan Pusat Statistik Kabupaten Indragiri Hilir. Statistik daerah Kabupaten Indragiri Hilir 2024. Indragiri Hilir: BPS-Statistics Indragiri Hilir; 2024. Available from: <https://inhilkab.bps.go.id/id/publication/2024/09/26/10308813891de11918eb9e53/statistik-daerah-kabupaten-indragiri-hilir-2024.html>.
- [3] Ridha MR, Yunita F. Pemilihan Bibit Kelapa Menggunakan Metode Nearest Mean Classifier Untuk Masyarakat Petani Kelapa Di Kabupaten Indragiri Hilir. J Perangkat Lunak. 2020;2(3):101–14. doi:[10.32520/jupel.v2i3.1306](https://doi.org/10.32520/jupel.v2i3.1306).

- [4] Usman U, Yunita F, Ridha MR. Improving classification accuracy of local coconut fruits with image augmentation and deep learning algorithm convolutional neural networks (CNN). *J Appl Data Sci.* 2025;6(1):1-19. doi:[10.47738/jads.v6i1.389](https://doi.org/10.47738/jads.v6i1.389).
- [5] Kaur A, Kukreja V, Garg N, Rajput K, Sharma R. Multi-class classification of coconut leaf disease using fine-tuned ResNet50 model. In: 2024 IEEE 9th International Conference for Convergence in Technology (I2CT); 2024. doi:[10.1109/I2CT61223.2024.10544047](https://doi.org/10.1109/I2CT61223.2024.10544047).
- [6] Hasan H, Al Kakoun R, Massaad G, Awad M. Advancing Agricultural Sustainability Through an AI-Powered Classification Framework of Plant Pests and Diseases. *IFIP Adv Inf Commun Technol, IFIPAICT.* 2024;715:349-62. Cited 0 times. doi:[10.1007/978-3-031-63227-3_25](https://doi.org/10.1007/978-3-031-63227-3_25).
- [7] Megalingam RK, Manoharan SK, Maruthababu RB. Integrated fuzzy and deep learning model for identification of coconut maturity without human intervention. *Neural Comput Appl.* 2024;36(11):6133-45. doi:[10.1007/s00521-023-09402-2](https://doi.org/10.1007/s00521-023-09402-2).
- [8] Amin M, Bindas A. Pengklasifikasi bibit kelapa menggunakan algoritma deep learning convolutional neural network. *J Perangkat Lunak.* 2024;6(3):405-13. doi:[10.32520/jupel.v6i3.3654](https://doi.org/10.32520/jupel.v6i3.3654).
- [9] Singh P, Verma A, Alex JSR. Disease and pest infection detection in coconut tree through deep learning techniques. *Comput Electron Agric.* 2021;182:105986. doi:[10.1016/j.compag.2021.105986](https://doi.org/10.1016/j.compag.2021.105986).
- [10] Kumar RR, Singh A. Utilizing Hybrid Intelligence: A CNN-SVM Method for Accurate Classification of Neem Leaf Diseases. 2024 IEEE 3rd World Conf Appl Intell Comput AIC. 2024;1530-3. doi:[10.1109/AIC61668.2024.10730833](https://doi.org/10.1109/AIC61668.2024.10730833).
- [11] Kavithamani V, UmaMaheswari S. Investigation of deep learning for whitefly identification in coconut tree leaves. *Intell Syst Appl.* 2023;20:200290. doi:[10.1016/j.iswa.2023.200290](https://doi.org/10.1016/j.iswa.2023.200290).
- [12] Yao Z, Huang M. Deep learning in tropical leaf disease detection: advantages and applications. *Trop Plants.* 2024;3(1):e020. doi:[10.48130/tp-0024-0018](https://doi.org/10.48130/tp-0024-0018).
- [13] Muni A, Amin M. Deteksi dan klasifikasi hama dan penyakit tanaman kelapa menggunakan Nearest Mean Classifier di Kabupaten Indragiri Hilir. *J Perangkat Lunak.* 2024;6(3):414-27. doi:[10.32520/jupel.v6i3.3655](https://doi.org/10.32520/jupel.v6i3.3655).
- [14] Muni A, Jibril M. Penerapan metode Naive Bayes classifier dalam pemilihan kualitas bibit kelapa untuk masyarakat petani kelapa di Indragiri Hilir. *J Perangkat Lunak.* 2023;5(3):313-22. doi:[10.32520/jupel.v5i3.2780](https://doi.org/10.32520/jupel.v5i3.2780).
- [15] Liu Q, Zhang Y, Chen J, Sun C, Huang M, Che M, Li C, Lin S. An improved DeepLab V3+ network-based coconut CT image segmentation method. *Front Plant Sci.* 2023;14:1139666. doi:[10.3389/fpls.2023.1139666](https://doi.org/10.3389/fpls.2023.1139666).
- [16] Megalingam RK, Kuttankulangara Manoharan S, Babu DHTA, Sriram G, Lokesh K, Kariparambil Sudheesh S. Coconut trees classification based on height, inclination, and orientation using MIN-SVM algorithm. *Neural Comput Appl.* 2023;35(16):12055-12071. doi:[10.1007/s00521-023-08339-w](https://doi.org/10.1007/s00521-023-08339-w).
- [17] Hieu NTT, Trieu NM, Thinh NT. Using Artificial Neural Network to grade internal quality of coconuts based on density. *Lect Notes Mech Eng.* 2022;413-23. Doi: [10.1007/978-981-19-1968-8_33](https://doi.org/10.1007/978-981-19-1968-8_33).
- [18] Prasetyo DY, Rianto B, Rais MS, Suwanti N. Diagnosa Dini Penyakit Mata Menerapkan Metode Case Based Reasoning (CBR). *J. Media Inform. Budidarma.* 2021 Apr;5(2):360-9.
- [19] Yodrot T, Sutacha C, Orachon T, Jangjongdee N, Boonyasuwananno S. A study on the potency of hybrid models: Detecting diseases in cucumber leaves with pre-trained CNNs and SVM. In: 12th International Electrical Engineering Congress (iEECON 2024). 2024. doi: [10.1109/iEECON60677.2024.10537828](https://doi.org/10.1109/iEECON60677.2024.10537828).
- [20] Kumar RR, Chauhan R, Dhondiyal SA, Singh A. Deep learning-driven diagnosis: A CNN-SVM hybrid approach for automated detection of strawberry leaf diseases. In: 2024 IEEE 3rd World Conference on Applied Intelligence and Computing (AIC). 2024. p. 1467-70. doi: [10.1109/AIC61668.2024.10731051](https://doi.org/10.1109/AIC61668.2024.10731051).

- [21] Geng M, Wang Y, Tian Y, Huang T. CNUSVM: Hybrid CNN-uneven SVM model for imbalanced visual learning. In: 2016 IEEE 2nd International Conference on Multimedia Big Data (BigMM). 2016. p. 186-93. doi: [10.1109/BigMM.2016.19](https://doi.org/10.1109/BigMM.2016.19).
- [22] Özgür F, Arian N, Karadağ OO. Comparison of a deep learning and a hybrid model for classification of an unbalanced urgent cases dataset for human faces. In: 9th International Conference on Computer Science and Engineering (UBMK); 2024. p. 563-8. doi: [10.1109/UBMK63289.2024.10773568](https://doi.org/10.1109/UBMK63289.2024.10773568).
- [23] Datt RM, Kukreja V. Pre-trained CNN and SVM based hybrid model for apple crops phenological phase recognition. In: ICAN 2022 - 3rd International Conference on Computing, Analytics and Networks - Proceedings. 2022. doi: [10.1109/ICAN56228.2022.10007213](https://doi.org/10.1109/ICAN56228.2022.10007213).
- [24] Hegazy AE, Makhoulf MA, El-Tawel GS. Improved salp swarm algorithm for feature selection. J King Saud Univ Comput Inf Sci. 2020;32(3):335-344. doi:[10.1016/j.jksuci.2018.06.003](https://doi.org/10.1016/j.jksuci.2018.06.003).
- [25] Banerjee D, Kukreja V, Hariharan S, Jain V, Vats S. Mango Disease Detection System Using CNN and SVM: A Comparative Study with Traditional Diagnostic Methods. In: 2023 World Conference on Communication and Computing, WCONF 2023. 2023. doi:[10.1109/WCONF58270.2023.10235224](https://doi.org/10.1109/WCONF58270.2023.10235224).
- [26] Wu J. Improve light weight convolutional neural networks for face recognition with multi-style recalibration module. Proc SPIE Int Soc Opt Eng. 2023;12602:126023F. doi:[10.1117/12.2668275](https://doi.org/10.1117/12.2668275).
- [27] Pham H, Tan Y, Singh T, Pavlopoulos V, Patnayakuni R. A multi-head attention-like feature selection approach for tabular data. Knowl-Based Syst. 2024;301:112250. doi:[10.1016/j.knosys.2024.112250](https://doi.org/10.1016/j.knosys.2024.112250).

UCAPAN TERIMAKASIH

Ucapan terimakasih kami sampaikan kepada Kemendikbudristek Direktorat Jendral Pendidikan Tinggi, Riset, dan Teknologi, Direktorat Riset, Teknologi, dan Pengabdian Kepada Masyarakat sebagai pemberi dana pada penelitian ini.