

IMPLEMENTASI CONVOLUTIONAL NEURAL NETWORK DALAM MENDETEKSI TINGKAT KEMATANGAN BUAH KAKAO

Rahman Wahabi Hasibuan, Insan Taufik, Mansur As, Said Iskandar Al Idrus, Zulfahmi Indra

Ilmu Komputer, Universitas Negeri Medan

Jl. William Iskandar Ps. V, Kenangan Baru, Medan, Indonesia

rahmanwahabi18@gmail.com

ABSTRAK

Indonesia merupakan negara agraris dengan sektor perkebunan yang berperan penting dalam perekonomiannya. Kakao (*Theobroma cacao* L.) merupakan komoditas strategis yang berkontribusi pada ekspor, lapangan kerja, agribisnis, serta pertanian berkelanjutan. Namun, di Sumatera Utara, meskipun sektor perkebunan berkembang, produksi kakao menghadapi tantangan seperti alih fungsi lahan. Proses pemanenan kakao secara tradisional mengandalkan penilaian kematangan secara manual, yang rentan terhadap kesalahan akibat kelelahan dan subjektivitas manusia. *Convolutional Neural Network* (CNN) telah banyak digunakan dalam pengolahan citra karena kemampuannya mengenali pola dengan akurasi tinggi. Penelitian ini mengusulkan penggunaan CNN dengan *Transfer Learning* berbasis EfficientNetB0 untuk mengklasifikasikan tingkat kematangan buah kakao. Dataset terdiri dari 360 gambar dalam kategori Mentah, Matang, Busuk, dan Unclassified, dengan teknik pra-pemrosesan seperti *resizing*, *noise*, rotasi, *flipping*, *cropping*, dan penghapusan latar belakang. Dataset dibagi menjadi 70% untuk pelatihan dan 30% untuk validasi, dengan optimasi hyperparameter. Model mencapai akurasi tinggi sebesar 99,71% pada data uji. Evaluasi menggunakan *confusion matrix* dan *classification report* menunjukkan kemampuan generalisasi yang baik. Selain itu, model berhasil diimplementasikan dalam aplikasi Android dengan fitur klasifikasi, riwayat, informasi, panduan, serta autentikasi pengguna. Sistem ini memungkinkan identifikasi kematangan buah kakao secara real-time dan praktis bagi petani.

Kata kunci : Aplikasi Android, Convolutional Neural Network, EfficientNetB0, Identifikasi Kematangan Kakao, Pengolahan Citra.

1. PENDAHULUAN

Indonesia adalah negara agraris dengan sektor pertanian sebagai tulang punggung ekonomi, di mana Provinsi Sumatera Utara memiliki peran penting melalui subsektor perkebunan seperti karet, kelapa sawit, dan kakao yang berpotensi besar di pasar internasional [1]. Kakao (*Theobroma cacao* L.) menjadi komoditas penting ekspor, menciptakan lapangan kerja, mendukung agribisnis, dan berkontribusi pada kelestarian lingkungan[2]. Peningkatan budidaya kakao diharapkan mampu meningkatkan produktivitas dan pendapatan petani[3]. Namun, dibandingkan dengan kelapa sawit dan karet, pertumbuhan kakao di Sumatera Utara cenderung lebih lambat akibat tantangan seperti alih fungsi lahan [4].

Sumatera merupakan produsen kakao terbesar kedua di Indonesia setelah Sulawesi[5]. Di Sumatera Utara, luas tanam kakao meningkat dari 54.314 hektar (2019) menjadi 54.467 hektar (2021), dengan produksi naik dari 34.792 ton menjadi 36.310 ton, khususnya di daerah Deli Serdang, Mandailing Natal, dan Nias Selatan[6] [7].

Penentuan tingkat kematangan kakao secara manual oleh petani sering menimbulkan kesalahan karena faktor subjektif dan kesulitan membedakan warna buah yang mirip[8]. Oleh karena itu, CNN diusulkan karena kemampuannya mengenali pola citra secara akurat dan otomatis. CNN yang meniru cara kerja sistem visual manusia, akan diimplementasikan ke aplikasi Android agar mudah diakses petani,

mengingat tingginya kepemilikan smartphone di Indonesia (89.45%)[9].

Berbagai studi menunjukkan efektivitas CNN dalam klasifikasi buah, seperti jeruk manis (akurasi 97.52% training, 92% testing)[10]. Penelitian dengan dataset Fruit-360 (15 dari 111 kelas) memperoleh akurasi 100% saat training (loss 0.012) dan 91.42% pada pengujian[11]. CNN juga diterapkan untuk menentukan kematangan kelapa sawit guna mengurangi ketergantungan pada penilaian manusia[12]. Selain itu, riset pada mangga Badami menggunakan CNN untuk klasifikasi kematangan[13]. Hasil-hasil ini menunjukkan efektivitas CNN dalam penilaian kematangan buah .

2. TINJAUAN PUSTAKA

2.1. Penelitian terdahulu

Penelitian sebelumnya telah mengembangkan sistem klasifikasi tingkat kematangan buah kakao menggunakan metode *Discrete Cosine Transform* (DCT) dan *K-Nearest Neighbor* (K-NN), yang menghasilkan akurasi tertinggi sebesar 83,33%[14]. Pendekatan lain menggunakan ekstraksi warna HSV dengan metode K-NN, menghasilkan akurasi, presisi, dan recall sebesar 90% pada nilai $k = 1$ [8]. Meskipun metode ini menunjukkan hasil yang cukup baik, pendekatan berbasis algoritma klasik seperti K-NN memiliki keterbatasan dalam menangani kompleksitas fitur visual dan variasi data. Oleh karena itu, digunakanlah metode *Convolutional Neural Network* (CNN) yang telah terbukti efektif dalam klasifikasi

berbagai buah, seperti jeruk manis (akurasi 97.52% training, 92% testing)[10]. Penelitian dengan dataset Fruit-360 (15 dari 111 kelas) memperoleh akurasi 100% saat training (loss 0.012) dan 91.42% pada pengujian[11]. CNN juga diterapkan untuk menentukan kematangan kelapa sawit guna mengurangi ketergantungan pada penilaian manusia[12]. Selain itu, riset pada mangga Badami menggunakan CNN untuk klasifikasi kematangan[13]. Hasil-hasil ini menunjukkan efektivitas CNN dalam penilaian kematangan buah

2.2. Kakao dan Jenis-Jenisnya

Kakao (*Theobroma cacao* L.) berasal dari hutan hujan tropis Amerika Selatan dan dikenal sebagai tanaman perkebunan yang ideal bagi petani kecil karena dapat berbunga dan berbuah sepanjang tahun. Kakao memiliki dua jenis utama di Indonesia: kakao mulia (Criollo) dan kakao lindak (Forastero dan Trinitario), yang berbeda dalam warna buah dan karakteristiknya. Buah kakao yang matang berwarna kuning hingga oranye dan mengandung pulp berlemak 40–50% [15].



Gambar 1. Buah Kakao

2.3. Citra warna



Gambar 2. Citra Warna (RGB)

Citra warna adalah gambar yang dibentuk oleh kombinasi tiga warna dasar: merah (*Red*), hijau (*Green*), dan biru (*Blue*), yang menghasilkan 16.777.216 warna yang berbeda. Setiap piksel dalam gambar RGB menyimpan 8 bit (1 *byte*) untuk setiap warna dasar, memungkinkan representasi warna yang sangat banyak dan disebut sebagai *true color*[16].

2.4. Machine Learning

Machine Learning (ML) adalah cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma yang dapat belajar dari data untuk meningkatkan prediksi atau keputusan. Dua pendekatan utama dalam ML adalah *supervised learning*, di mana model dilatih dengan data berlabel, dan *unsupervised learning*, yang digunakan untuk menemukan pola tanpa data berlabel [17].

2.5. Deep learning

Deep learning adalah subbidang *machine learning* yang menggunakan jaringan saraf tiruan dengan banyak lapisan untuk mempelajari representasi fitur dari data kompleks. Teknik ini sangat efektif untuk tugas-tugas rumit seperti pengenalan gambar, suara, dan bahasa alami, meskipun memerlukan data dalam jumlah besar dan sumber daya komputasi yang tinggi[18].

2.6. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) jenis *deep neural network* yang dirancang untuk pengolahan citra. CNN lebih efisien dibandingkan dengan MLP dalam menangani data dua dimensi karena dapat mempertahankan informasi spasial gambar. Model CNN pertama kali dikembangkan oleh Kunihiko Fukushima dan kemudian disempurnakan oleh Yann LeCun untuk mengenali tulisan tangan, dengan popularitas meningkat setelah kemenangan AlexNet di kompetisi ImageNet[19].

2.7. EfficientNet-B0

EfficientNet-B0 adalah varian model EfficientNet yang dikembangkan oleh Google AI untuk memberikan performa tinggi dengan efisiensi komputasi yang lebih baik. Model ini menggunakan Depthwise Separable Convolutions untuk mengurangi jumlah parameter tanpa mengorbankan kinerja, serta menerapkan strategi penskalaan untuk kedalaman, lebar, dan resolusi model yang seimbang[14].

3. METODE PENELITIAN

Penelitian ini merupakan jenis *Research and Development* (R&D), bertujuan mengembangkan sistem klasifikasi kematangan buah kakao berbasis *Convolutional Neural Network* (CNN). Sistem ini diharapkan dapat meningkatkan akurasi klasifikasi serta kualitas panen.

Berikut Merupakan langkah-langkah tahapan penelitian yang akan dilakukan dalam penelitian ini.



Gambar 3. Flowchart Penelitian

3.1. Studi Literatur

Studi dilakukan untuk memahami metode CNN, pengolahan citra, serta aplikasi teknologi dalam sektor pertanian.

3.2. Pengumpulan Data

Pengumpulan Data primer dikumpulkan dari gambar buah kakao di Desa Tanjung Harapan, Kec. Bilah Barat, Kab. Labuhanbatu. Sebanyak 120 gambar per kategori (matang, busuk, mentah) dikumpulkan dengan kamera smartphone 50 MP. Label tambahan "Unclassified" digunakan untuk gambar-gambar yang tidak masuk kategori utama, yang diambil secara acak dari internet. Tujuannya untuk menjaga kualitas dataset selama pelatihan model.

Tabel 1. Tabel Data Primer

Mentah	Matang	Busuk
		

3.3. Praproses Data

Dataset yang terkumpul akan melalui tahap praproses meliputi *background removal* untuk memfokuskan pada objek utama, resize ke 224x224 piksel, serta augmentasi data berupa random noise, rotasi 45 derajat, *horizontal* dan *vertical flip*, serta *crop*. Langkah ini bertujuan meningkatkan ketahanan dan akurasi model terhadap berbagai kondisi nyata.

3.4. Perancangan Model CNN

Model dibangun menggunakan EfficientNetB0 sebagai feature extractor (mode frozen). Setelahnya ditambahkan *GlobalAveragePooling2D*, dua *Dense* layer masing-masing dengan 512 dan 256 neuron beraktivasi ReLU, serta dua *Dropout* layer untuk menghindari overfitting. Terakhir, ditambahkan *Dense output* layer dengan 4 neuron dan aktivasi Softmax sebagai output.

Tabel 2. Arsitektur CNN yang Telah Dimodifikasi

Layer	Filter	Size	Activation
EfficientNetB0 (base)	-	(7,7, 1280)	-
GlobalAveragePooling2D	-	(1280)	-
Dense	512	(512)	ReLU
Dropout	-	(512)	-
Dense	256	(256)	ReLU
Dropout	-	(256)	-
Dense (Output Layer)	4	4	Softmax

Selain memilih lapisan yang akan diterapkan saat melatih model, penting juga untuk mengatur hyperparameter yang digunakan dalam proses pelatihan. Pengaturan ini bertujuan untuk mengoptimalkan pembelajaran model agar menghasilkan hasil yang terbaik selama proses pelatihan. *Hyperparameter* yang akan digunakan dalam penelitian ini meliputi pengaturan Learning Rate, rasio antara data latih dan data uji, fungsi Loss, optimasi Loss, serta jumlah Epoch. Rincian masing-masing hyperparameter dapat dilihat dalam tabel 3.

Tabel 3. Nilai Hyperparameter yang digunakan pada Pelatihan Model

Hyperparameter	Jenis/nilai yang akan diuji
Fungsi Loss (FL)	Categorical Cross Entropy (CCE)
Optimasi Loss (OL)	Adaptive Moment Estimation (ADAM)
Batch Size (Latih dan Uji)	32, 64
Learning Rate (LR)	10^{-3} , 10^{-4} , 10^{-5}
Epochs	30
Rasio (Data Latih:Data Uji)	70:30

Tabel 3 menampilkan *hyperparameter* pelatihan model, dengan fungsi *loss* *Categorical Cross Entropy* (CCE) dipilih karena sesuai untuk klasifikasi multikategori dengan 4 kelas, menghitung selisih antara probabilitas prediksi dan label sebenarnya. Optimizer ADAM digunakan karena menyesuaikan learning rate secara adaptif dan mempercepat konvergensi pada CNN. Learning rate yang diuji adalah 10^{-3} , 10^{-4} , dan 10^{-5} , nilai kecil membuat pembelajaran lebih stabil, sedangkan nilai besar mempercepat konvergensi. Model dilatih selama 30 *epoch* untuk mencapai konvergensi tanpa *overfitting*. dengan rasio data latih dan uji sebesar 70:30 untuk evaluasi yang representatif.

3.5. Pengujian dan Evaluasi Model

Pengujian dilakukan untuk mengevaluasi model CNN menggunakan data gambar yang tidak dilibatkan saat pelatihan guna mengukur kemampuan klasifikasi kematangan buah kakao. Evaluasi dilakukan melalui fungsi *evaluate* dari TensorFlow dan analisis lebih lanjut menggunakan matriks kebingungan. Setelah prediksi diperoleh, akurasi dihitung berdasarkan jumlah prediksi yang benar sebagai ukuran kinerja

sistem. Persamaan untuk menghitung akurasi adalah sebagai berikut:

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (1)$$

Selain akurasi, *confusion matrix* juga menyediakan metrik lain seperti *precision*, *recall*, dan *f1 score*. Berikut adalah rumus untuk menghitung masing-masing metrik tersebut:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

$$\text{F1 - score} = 2 \times \frac{TP}{TP + FP + FN} \quad (4)$$

Precision adalah ukuran yang menunjukkan tingkat ketepatan model dalam memprediksi kasus positif. Selain itu, untuk analisis kinerja model yang lebih mendalam, *recall* atau sensitivitas dan nilai *f1-score* juga penting. *Recall* mengukur seberapa baik model mengidentifikasi semua kasus positif yang sebenarnya, sedangkan *f1-score* memberikan rata-rata harmonik dari *precision* dan *recall*, menawarkan keseimbangan antara kedua metrik tersebut.

3.6. Perancangan Sistem

Pada tahap ini, perancangan sistem meliputi flowchart yang dibuat untuk mempermudah membaca proses-proses yang terjadi pada sistem. Berikut ini gambar dari flowchart pada gambar 4.



Gambar 4. Flowchart Perancangan Sistem

3.7. Implementasi Sistem

Pada tahap pengembangan ini, model Convolutional Neural Network (CNN) yang telah dilatih akan diintegrasikan ke dalam aplikasi Android, memungkinkan pengguna untuk mengirimkan citra buah kakao dan menerima hasil analisis kematangan.


Model CNN, yang mengenali tingkat kematangan buah kakao (mentah, matang, busuk), akan diimplementasikan menggunakan format .tflite untuk memastikan model dapat dijalankan langsung di smartphone dengan Kotlin sebagai bahasa pemrograman. Dengan pendekatan ini, aplikasi dapat digunakan tanpa koneksi internet atau sumber daya komputasi tinggi, meningkatkan efisiensi dan kecepatan deteksi. Aplikasi ini juga dapat diakses di berbagai perangkat Android, memberikan solusi praktis dan skalabel untuk mendeteksi kematangan buah kakao, yang sangat bermanfaat bagi petani atau industri kakao untuk meningkatkan kualitas produksi dan mengurangi kerugian.

4. HASIL DAN PEMBAHASAN

4.1. Pengumpulan Data

Data dikumpulkan dengan mengambil gambar buah kakao lokal pada tiga tingkat kematangan: mentah, matang, dan busuk, menggunakan smartphone Poco F6 (50MP). Setiap kelas terdiri dari 120 gambar, total 360 gambar, dengan pencahayaan yang memadai dan jarak pengambilan kurang dari 20 cm. Kematangan buah divalidasi berdasarkan referensi studi kepustakaan. Contoh gambar dapat dilihat pada Tabel 4.

Tabel 4. Tabel Dataset



Penelitian ini menambahkan label *Unclassified* untuk gambar yang tidak sesuai dengan label mentah, matang, dan busuk. Data *Unclassified* diambil dari gambar acak di Kaggle dengan kualitas bervariasi, untuk meningkatkan adaptabilitas model terhadap gambar yang tidak terdefinisi.

4.2. Praproses Data

Proses praproses data meliputi augmentasi seperti resize ke 224x224 piksel, penambahan noise acak, rotasi 45°, flip horizontal dan vertikal, crop area tengah, serta penghapusan latar belakang. Langkah-langkah ini meningkatkan variasi dan kualitas dataset untuk pelatihan model.

Tabel 5. Tabel Proses Praproses Data

Langkah	Hasil
Resize	

Langkah	Hasil
Random Noise	
Rotasi	
Horizontal Flip	
Vertical Flip	
Crop	
Background Removal	

4.3. Membangun Model Convolution Neural Network (CNN)

Penelitian ini menggunakan CNN berbasis EfficientNetB0 dengan *Transfer Learning* untuk klasifikasi kematangan buah kakao dalam empat kelas: Busuk, Matang, Mentah, dan *Unclassified*. Model dilatih dengan gambar berukuran 224x224 piksel. Kelas *Unclassified* digunakan untuk gambar yang tidak sesuai dengan tiga label utama. *Transfer Learning* memanfaatkan model *pre-trained* untuk meningkatkan efisiensi dan akurasi. Dataset dibagi menjadi dua bagian: pelatihan (70%) dan validasi (30%) dengan parameter yang sesuai, menggunakan fungsi `image_dataset_from_directory`. Model EfficientNetB0 yang telah dilatih pada ImageNet diterapkan untuk tugas klasifikasi, memanfaatkan pengetahuan awal tentang fitur visual.

Tabel 6. Arsitektur EfficientNetB0

Layer	Filter	Size	Activation
EfficientNetB0 (base)	-	(7,7, 1280)	-
GlobalAveragePooling2D	-	(1280)	-
Dense	512	(512)	ReLU
Dropout	-	(512)	-
Dense	256	(256)	ReLU
Dropout	-	(256)	-
Dense (Output Layer)	4	4	Softmax


Model dilatih selama 30 epoch dengan beberapa kombinasi hyperparameter. Model terbaik memiliki akurasi latih 0.9994 dan akurasi uji 0.9971, dengan loss yang sangat rendah.

Tabel 7. Nilai Pengukuran Model


Total Epoch	Batch size	Learning Rate	Akurasi Latih	Loss Latih	Akurasi Uji	Loss Uji
30	32	10^{-3}	0.9996	0.0041	0.9896	0.0364
		10^{-4}	0.9994	0.0028	0.9971	0.0090
		10^{-5}	0.9856	0.0585	0.9855	0.0519
	64	10^{-3}	0.9928	0.0410	0.9919	0.0338
		10^{-4}	0.9993	0.0031	0.9965	0.0105
		10^{-5}	0.9998	7.4347e-04	0.9971	0.0090

Grafik ini menunjukkan akurasi model mencapai 0.996, stabil di atas 0.984, dengan loss berkisar antara 0.004 hingga 0.006, menunjukkan kesalahan prediksi yang rendah dan konsisten.

Model memiliki akurasi tinggi dengan klasifikasi yang benar untuk 421 sampel Busuk, 436 sampel Matang, 413 sampel Mentah, dan 453 sampel Unclassified. Kesalahan klasifikasi sangat sedikit.



Gambar 5. Grafik Hasil Akurasi dan Loss pada Pelatihan Model berdasarkan Epochs

Gambar 6. Hasil Uji *Confusion Matrix*

Tabel 8 menunjukkan hasil evaluasi model klasifikasi menggunakan metrik *Precision*, *Recall*, *F1-Score*, dan *Accuracy* untuk empat kelas. Kelas 0, 1, dan 3 memiliki nilai sempurna (1.00) untuk semua metrik, menunjukkan klasifikasi tanpa kesalahan. Kelas 2 memiliki *Precision* 0.99, *Recall* 1.00, dan *F1-Score* 0.99, mengindikasikan sedikit kesalahan namun performa tetap sangat baik. *Accuracy* keseluruhan model mencapai 0.99, menunjukkan tingkat ketepatan yang tinggi dalam klasifikasi.


Tabel 8. Klasifikasi Laporan

Class	Precision	Recall	F1-Score	Accuracy
0	1.00	1.00	1.00	0.99
1	1.00	1.00	1.00	
2	0.99	1.00	0.99	
3	1.00	1.00	1.00	

4.4. Implementasi Sistem

Penelitian ini berfokus pada pengembangan suatu aplikasi yang dapat diinstal dan digunakan pada perangkat seluler berbasis sistem operasi Android.


4.5. Implementasi Login

Gambar 7. Hasil Implementasi Halaman *Login*

Untuk mengakses semua fitur aplikasi, pengguna wajib memiliki akun pribadi. Proses login dilakukan dengan mengisi informasi akun yang telah didaftarkan sebelumnya, yaitu nama pengguna dan kata sandi. Bagi pengguna baru, tersedia tombol Daftar untuk membuat akun baru.


4.6. Implementasi Halaman Registrasi

Fitur pendaftaran aplikasi memerlukan pengisian formulir username, password, dan pertanyaan keamanan. Setelah menekan tombol Daftar, data divalidasi dan disimpan dalam database. Validasi memastikan username unik dan semua field terisi. Password di-hash untuk keamanan. Jika berhasil, pengguna diarahkan ke halaman login.

Gambar 8. Hasil Implementasi Halaman *Registrasi*

4.7. Implementasi Halaman Lupa Password


Halaman lupa password dirancang sederhana dan intuitif, memungkinkan pengguna mereset password dengan memasukkan informasi yang diperlukan. Fitur ini meningkatkan keamanan akun pengguna.



Gambar 9. Hasil Implementasi Halaman Lupa Password

4.8. Implementasi Halaman Utama


Gambar 10 menampilkan halaman utama aplikasi CaRa dengan desain sederhana dan intuitif, dilengkapi ikon buah kakao dan tombol navigasi untuk fitur klasifikasi, riwayat, informasi, dan panduan penggunaan.



Gambar 10. Hasil Implementasi Halaman Utama

4.9. Implementasi Halaman Klasifikasi


Gambar 11 menunjukkan antarmuka tahap klasifikasi dalam aplikasi, di mana pengguna dapat mengambil foto atau mengunggah gambar kakao. Aplikasi memberikan panduan singkat tentang kualitas gambar yang baik. Setelah diproses, hasil klasifikasi dan tingkat akurasi ditampilkan. Antarmuka yang sederhana dan intuitif memudahkan interaksi, dengan fitur riwayat klasifikasi untuk melacak hasil sebelumnya.



Gambar 11. Hasil Implementasi Halaman Klasifikasi

4.10. Implementasi Halaman *History*


Gambar 12 menampilkan antarmuka halaman riwayat aplikasi, yang menampilkan daftar hasil klasifikasi sebelumnya, termasuk nama pengguna, kategori hasil (misalnya "Busuk"), serta tanggal dan waktu klasifikasi. Desain antarmuka yang sederhana memudahkan pengguna mengakses dan meninjau riwayat klasifikasi. Fitur ini berguna untuk memantau perkembangan kualitas buah kakao, menganalisis pola, dan mengambil tindakan guna meningkatkan produksi.



Gambar 12. Hasil Implementasi Halaman *History*

4.11. Implementasi Halaman *About*

Menampilkan antarmuka halaman About aplikasi, yang memberikan informasi dasar seperti tujuan pengembangan, teknologi yang digunakan (termasuk *deep learning*), dan kontak pengembang. Desain sederhana dan informatif memudahkan pengguna memahami fungsi dan cara kerja aplikasi. Informasi kontak memungkinkan pengguna memberikan umpan balik atau mengajukan pertanyaan.



Gambar 13. Hasil Implementasi Halaman *About*

4.12. Implementasi Halaman *Guide*


Menampilkan antarmuka halaman panduan aplikasi, yang memberikan instruksi singkat tentang langkah-langkah klasifikasi kematangan buah kakao. Dengan visual ikon buah kakao, pengguna diarahkan untuk menekan tombol klasifikasi, lalu memilih metode unggah gambar (foto baru atau gambar yang ada). Desain ramah pengguna ini memudahkan pengoperasian aplikasi, memastikan pengguna dapat memulai klasifikasi dengan cepat dan mudah.



Gambar 14. Hasil Implementasi Halaman Guide

4.13. Implementasi Halaman Profile

Menampilkan antarmuka halaman profil aplikasi, yang menampilkan informasi pengguna dan tombol *Log Out*. Desain sederhana dan minimalis memudahkan akses informasi profil dan fungsi *logout*. Halaman ini penting untuk sistem autentikasi, membantu pengguna mengelola akun dan menjaga privasi data.



Gambar 15. Hasil Implementasi Halaman Profile

5. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengembangkan model klasifikasi kematangan buah kakao menggunakan CNN dengan *Transfer Learning* berbasis *EfficientNetB0*, yang mencapai akurasi tinggi sebesar 99,71% pada data uji. Proses pengolahan data mencakup pengumpulan 360 gambar buah kakao dalam tiga kategori utama (Mentah, Matang, Busuk) serta label tambahan *Unclassified*, diikuti dengan berbagai teknik augmentasi seperti *resizing*, *noise*, *rotasi*, *flipping*, *cropping*, dan *background removal* untuk meningkatkan variasi data. Model dikembangkan dengan pembagian dataset 70% untuk pelatihan dan 30% untuk validasi, serta dioptimalkan

melalui eksperimen *hyperparameter* dengan *batch size* dan *learning rate* yang bervariasi. Evaluasi menggunakan *confusion matrix* dan *classification report* menunjukkan bahwa model memiliki kemampuan generalisasi yang sangat baik dengan kesalahan minimal. Implementasi sistem dalam bentuk aplikasi Android juga berhasil dilakukan, menyediakan fitur utama seperti klasifikasi, riwayat, informasi, panduan, serta autentikasi pengguna, sehingga memungkinkan identifikasi kematangan buah kakao secara real-time dan praktis untuk pengguna.

DAFTAR PUSTAKA

- [1] B. M. Pratama, M. I. Ali, M. H. Wati, R. Rhonsina, and S. Wulandari, "Kontribusi Subsektor Perkebunan Dalam Mendukung Pertumbuhan Ekonomi Masyarakat di Sumatera Utara," *El-Mal J. Kaji. Ekon. Bisnis Islam*, vol. 4, no. 6, pp. 1637–1645, 2023, doi: 10.47467/elmal.v4i6.3079.
- [2] R. Linda dan Siska, "Pertumbuhan Biji Kakao (*Theobroma cacao* L.) Dengan Variasi Konsentrasi Air Kelapa Dan Lama Waktu Perendaman," *J. Buana Sains*, vol. 21, no. 2, pp. 2527–5720, 2021.
- [3] E. Fitri, R. Erlinda, and Nelson, "Analisis Pendapatan Usahatani Kakao (*Theobroma Cacao*) Di Kecamatan Lareh Sago Halaban Kabupaten Limapuluh Kota," *Ekon. Pertan. Dan Agribisnis*, vol. 6, no. 4, pp. 1462–1468, 2022, [Online]. Available: <https://jepa.ub.ac.id/index.php/jepa/article/view/1353>
- [4] J. Siahaan, K. Butar-butur, O. Lawolo, and H. Nainggolan, "Daya Saing Perkebunan dan Kontribusinya terhadap Pertumbuhan Ekonomi Sumatera Utara Masa Covid-19," *J. Agribisnis*, pp. 74–87, 2023, [Online]. Available: <http://journal.unilak.ac.id/index.php/agr/article/view/12193>
- [5] L. R. S. . A. R. . Handayani T., "Peramalan Tingkat Produksi Kakao Tahun 2021 Di Provinsi Sumatera Utara Dengan Metode Double Exponential Smoothing Brown Forecasting of Cocoa Production Level in 2021 in North Sumatra Province Using Double Exponential Smoothing Brown Method," *Math. Appl. J. UIN Imam Bonjol Padang*, vol. 3, no. 1, pp. 82–91, 2021.
- [6] "Badan Pusat Statistik Provinsi Sumatera Utara," 2021.
- [7] K. P. Pinandito, I. A. Wunawarsih, P. Arimbawa, and D. Dima, "FAKTOR PENDORONG ALIH FUNGSI LAHAN KAKAO MENJADI KELAPA SAWIT DI DESA LEMBAH SUBUR KECAMATAN DANGIA KABUPATEN KOLAKA TIMUR," vol. 2, no. 4, pp. 1–12, 2023.
- [8] I. Mahendra and N. Rachmat, "Klasifikasi

- Tingkat Kematangan Buah Kakao Berdasarkan Fitur Warna Menggunakan Algoritma K-Nearest Neighbor,” ... *Ilmu Komput. dan ...*, vol. 4, no. 1, p. 31~42, 2023, doi: 10.35957/algoritme.xxxx.
- [9] D. Prasetyawan and R. Gatra, “Model Convolutional Neural Network untuk Mengukur Kepuasan Pelanggan Berdasarkan Ekspresi Wajah,” *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 3, pp. 661–673, 2022, doi: 10.28932/jutisi.v8i3.5493.
- [10] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, and R. R. Pratama, “Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network,” *INOVTEK Polbeng - Seri Inform.*, vol. 6, no. 2, p. 259, 2021, doi: 10.35314/isi.v6i2.2104.
- [11] F. F. Maulana and N. Rochmawati, “Klasifikasi Citra Buah Menggunakan Convolutional Neural Network,” *J. Informatics Comput. Sci.*, vol. 1, no. 02, pp. 104–108, 2020, doi: 10.26740/jinacs.v1n02.p104-108.
- [12] R. Triyogi, R. Magdalena, and B. Hidayat, “Mendeteksi Kematangan Buah Kelapa Sawit Menggunakan Convolutional Neural Network Deep Learning,” *J. Nas. SAINS dan Tek.*, vol. 1, no. 1, pp. 22–27, 2023.
- [13] A. Arkadia, S. Ayu Damayanti, and D. Sandya Prasvita, “Klasifikasi Buah Mangga Badami Untuk Menentukan Tingkat Kematangan dengan Metode CNN,” *Pros. Semin. Nas. Mhs. Bid. Ilmu Komput. dan Apl.*, vol. 2, no. 2, pp. 158–165, 2021.
- [14] Nabila Asryani Sundari, Rita Magladena, and Sofia Saidah, “Klasifikasi Jenis Kulit Wajah Menggunakan Metode Covolutional Neural Network (CNN) Efficientnet-B0,” *e-Proceeding Eng.*, vol. 8, no. 6, pp. 3180–3187, 2022.
- [15] Y. RIONO, “PERTUMBUHAN BIBIT KAKAO (Teobroma cacao L) DENGAN BERBAGAI PEMBERIAN DOSIS SERBUK GERGAJI PADA VARIETAS (BUNDO-F1) DI TANAH GAMBUT,” *Selodang Mayang J. Ilm. Badan Perenc. Pembang. Drh. Kabupaten Indragiri Hilir*, vol. 6, no. 3, pp. 163–171, 2020, doi: 10.47521/selodangmayang.v6i3.175.
- [16] Juandri and N. Anwar, “Pengenalan Warna Terhadap Objek Dengan Model Analisis Elemen Data Warna Gambar Berbasis Deep Neural Network,” *BULLET J. Multidisiplin Ilmu*, vol. 2, no. 1, pp. 23–31, 2023, [Online]. Available: <https://journal.mediapublikasi.id/index.php/bullet>
- [17] H. Abijono, P. Santoso, and N. L. Anggreini, “Algoritma Supervised Learning Dan Unsupervised Learning Dalam Pengolahan Data,” *J. Teknol. Terap. G-Tech*, vol. 4, no. 2, pp. 315–318, 2021, doi: 10.33379/gtech.v4i2.635.
- [18] A. Raup, W. Ridwan, Y. Khoeriyah, S. Supiana, and Q. Y. Zaqiah, “Deep Learning dan Penerapannya dalam Pembelajaran,” *JIIIP - J. Ilm. Ilmu Pendidik.*, vol. 5, no. 9, pp. 3258–3267, 2022, doi: 10.54371/jiip.v5i9.805.
- [19] R. Jannah, M. Walid, and H. Hoiriyah, “Sistem Pengenalan Citra Dokumen Tanda Tangan Menggunakan Metode CNN (Convolutional Neural Network),” *Energy - J. Ilm. Ilmu-Ilmu Tek.*, vol. 12, no. 2, pp. 1–8, 2022, doi: 10.51747/energy.v12i2.1116.