

Implementasi ResNet-50 dalam Sistem Deteksi Kematangan Tandan Buah Segar (TBS) Sawit

Implementation of ResNet-50 in a Fresh Fruit Bunch (FFB) Ripeness Detection System for Oil Palm

¹M. Rafli Al Thoriq Mustafa*, ²Muhammad Fikry, ³Said Fadlan Anshari

^{1,2,3}Program Studi Teknik Informatika, Fakultas Teknik, Universitas Malikussaleh Aceh, Indonesia

*e-mail: m.rafli.220170006@mhs.unimal.ac.id

(received: 14 April 2026, revised: 22 May 2026, accepted: 23 May 2026)

Abstrak

Kualitas *crude palm oil* (CPO) sangat bergantung pada akurasi penyortiran tingkat kematangan tandan buah segar (TBS) sawit. Proses sortasi manual di pabrik saat ini rentan terhadap *human error* dan subjektivitas. Penelitian ini bertujuan mengotomatisasi objektivitas sortasi menggunakan *deep learning* berarsitektur ResNet-50 dengan pendekatan *transfer learning* untuk mengklasifikasikan TBS ke dalam tiga kategori (Belum Masak, Masak, dan Terlalu Masak). Model komputasi ini diintegrasikan ke dalam aplikasi web berbasis *Flask* untuk operasional nirkabel di pabrik. Hasil pengujian menunjukkan akurasi validasi sebesar 90,94% dan *F1-Score* 91%. Validasi lapangan secara langsung terhadap 42 sampel data primer menghasilkan tingkat keberhasilan klasifikasi 83,33%. Penerapan ambang batas probabilitas (*confidence threshold*) 75% terbukti efektif mencegah kesalahan prediksi (*zero misclassification*), dan uji reliabilitas *Cohen's Kappa* mencatatkan nilai 0,769 (*Substantial Agreement*) yang selaras dengan penilaian petugas ahli. Kesimpulannya, sistem berbasis ResNet-50 ini terbukti andal, objektif, dan siap direplikasi untuk menjaga konsistensi mutu pada industri pengolahan sawit.

Kata kunci: *deep learning, Flask, kelapa sawit, ResNet-50, transfer learning*

Abstract

The quality of *Crude Palm Oil* (CPO) is highly dependent on the accuracy of sorting the ripeness level of oil palm Fresh Fruit Bunches (FFB). Manual sorting processes currently used in factories are vulnerable to human error and subjectivity. This study aims to automate the objectivity of the sorting process using a deep learning model based on the ResNet-50 architecture with a transfer learning approach to classify FFB into three categories: Unripe, Ripe, and Overripe. The computational model was integrated into a web-based application using the Flask framework to support wireless operational use in factories. Experimental results showed a validation accuracy of 90.94% and an *F1-score* of 91%. Direct field validation using 42 primary data samples achieved a classification success rate of 83.33%. The implementation of a 75% confidence threshold proved effective in preventing prediction errors (*zero misclassification*), while the *Cohen's Kappa* reliability test achieved a score of 0.769, indicating *Substantial Agreement* with expert evaluators. In conclusion, the ResNet-50-based system demonstrated reliable and objective performance and is considered ready for replication to maintain quality consistency in the palm oil processing industry.

Keywords: *deep learning, Flask, oil palm, ResNet-50, transfer learning*

1 Pendahuluan

Sektor perkebunan kelapa sawit memegang peran strategis dalam perekonomian Indonesia. Sebagai pemasok utama minyak sawit dunia, prioritas pengembangan industri kini ditekankan pada pengolahan pascapanen guna menjamin mutu *Crude Palm Oil* (CPO) secara berkelanjutan [1], [2]. Standar kualitas rendemen CPO ini sangat bergantung pada rasio kematangan Tandan Buah Segar (TBS) yang diproses. Sayangnya, proses penyortiran (*grading*) TBS di mayoritas Pabrik Kelapa Sawit (PKS) saat ini masih mengandalkan inspeksi visual manusia. Metode manual ini tidak hanya memakan waktu, tetapi juga sangat subjektif dan rentan terhadap kelelahan (*human error*), sehingga

<http://sistemasi.ftik.unisi.ac.id>

berisiko meloloskan TBS mentah atau pengotor ke dalam mesin pengolahan yang pada akhirnya mendegradasi mutu minyak [3].

Berbagai riset terdahulu telah berupaya mengotomatisasi deteksi kematangan TBS, tetapi sebagian besar pendekatan difokuskan pada fase hulu, yakni deteksi di atas pohon menggunakan kamera seluler atau instrumen egrek termodifikasi [4], [5]. Pendekatan hulu ini menyisakan celah fungsionalitas yang nyata; akurasi sistem sering kali terdistorsi oleh objek penghalang seperti pelepah, dan pengadaan perangkat keras tambahan justru mendisrupsi efisiensi biaya (*cost*) bagi petani kelas menengah ke bawah. Merespons kesenjangan (*research gap*) tersebut, automasi deteksi kematangan akan jauh lebih tangguh dan rasional apabila dipusatkan di hilir, yakni pada rantai penyortiran PKS. Kondisi pencahayaan dan jarak pandang kamera yang terkontrol di area pabrik memberikan potensi besar untuk mengekstraksi fitur visual kematangan buah secara maksimal tanpa harus membebani anggaran operasional pekebun.

Untuk mencapai tingkat deteksi yang andal di pabrik, penerapan teknologi *deep learning*, khususnya arsitektur *convolutional neural networks* (CNN), menjadi solusi strategis karena kemampuannya dalam mengekstraksi representasi fitur citra yang kompleks secara adaptif tanpa intervensi manual [6], [7]. Dengan mengadaptasi standar penerimaan industri yang mengelompokkan kematangan dalam agregat kelas belum masak, masak, dan terlalu masak, penelitian ini menitikberatkan pada masalah optimalisasi model pendeteksi berbasis jaringan saraf tiruan [8].

Untuk menghadirkan sistem deteksi di PKS yang andal, penerapan arsitektur *deep learning Convolutional Neural Network* (CNN) menjadi solusi teknis yang paling menjanjikan. Oleh karena itu, penelitian ini secara spesifik bertujuan untuk mengoptimalkan kinerja arsitektur ResNet-50 menggunakan pendekatan *transfer learning* untuk mengklasifikasikan tingkat kematangan TBS secara akurat. Berbeda dengan penelitian sebelumnya yang umumnya hanya membagi ke dalam dua kelas biner, penelitian ini merumuskan klasifikasi ke dalam tiga agregat kelas agronomis (belum masak, masak, dan terlalu masak) agar selaras dengan hierarki standar operasional prosedur penyortiran industri PKS. Kontribusi utama dari artikel ini adalah menghasilkan sistem *computer vision* yang tidak hanya tinggi secara akurasi algoritmik, tetapi juga disimulasikan ke dalam aplikasi pragmatis berbasis *Flask* dan diuji secara komprehensif keandalannya pada skenario lapangan sesungguhnya.

2 Tinjauan Literatur

Upaya automasi klasifikasi kematangan TBS sawit telah bertransformasi secara masif dari metode ekstraksi fitur konvensional menuju pendekatan komputasi cerdas. Studi awal menggunakan jaringan saraf tiruan telah dirintis sebagai fondasi awal untuk klasifikasi kematangan melalui pengolahan citra [9]. Evolusi teknologi dalam otomasi klasifikasi kematangan TBS telah bergeser dari ekstraksi fitur konvensional menuju pendekatan komputasi cerdas. Studi awal yang memanfaatkan sensor perangkat keras (seperti TCS3200) maupun pengolahan citra berbasis modifikasi ruang warna HSV [10], [11] telah berhasil membuktikan kelayakan mesin menggantikan mata manusia. Namun, pendekatan konvensional ini menemui jalan buntu pada aspek skalabilitas operasional karena rentan terhadap bias pencahayaan dinamis di pabrik dan diuji pada volume data prototipe yang sangat minim.

Mengatasi kelemahan ekstraksi fitur secara manual, tren penelitian belakangan ini bergeser pada implementasi *deep learning* yang menargetkan fase hulu, yakni pendeteksian langsung di kebun saat proses pemanenan. Penelitian terdahulu [4], [5] mengusulkan sistem deteksi *realtime* menggunakan arsitektur *CenterNet* berbasis seluler dan integrasi kecerdasan buatan pada instrumen "Egrek Digital". Pendekatan di fase perkebunan ini mampu menyentuh metrik akurasi 90%, namun secara praktis menghadapi rintangan fisik dan hambatan sosio-ekonomi yang signifikan. Secara visual, jarak bidik kamera yang berjauhan dengan pohon serta halangan objek pasif seperti pelepah sawit berpotensi mendistorsi ekstraksi matriks fitur oleh model. Dari sudut pandang ergonomi dan ekonomi industri, pengadaan instrumen pemanenan termodifikasi ini justru mendisrupsi efisiensi biaya (*cost*) operasional petani skala menengah ke bawah, sehingga probabilitas adopsi teknologinya menjadi tidak optimal dan tidak menjawab masalah sortasi akhir.

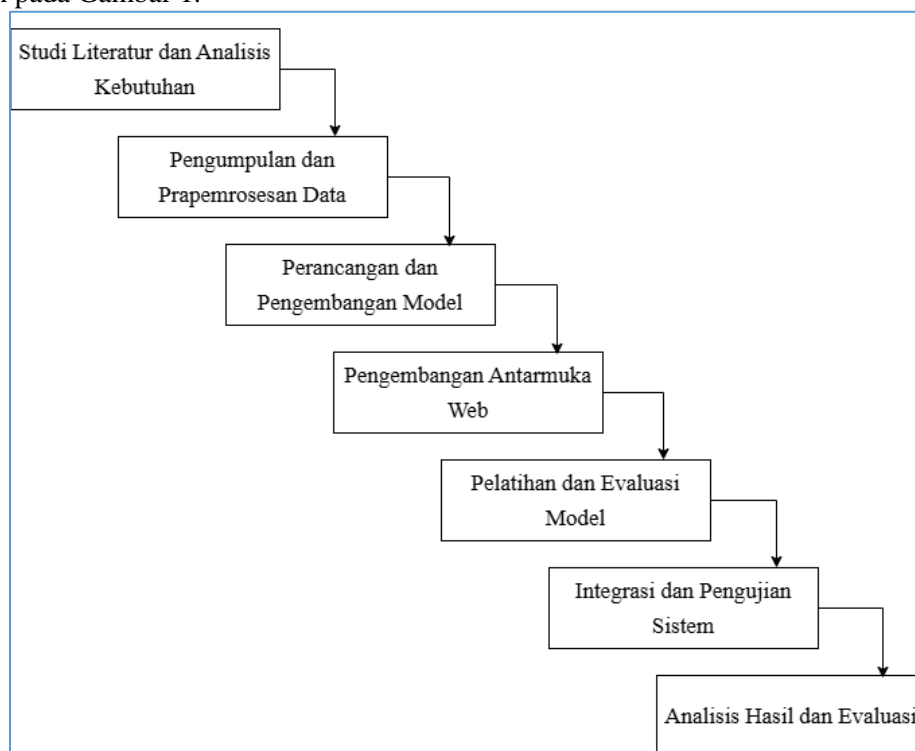
Dari sisi arsitektur pemrosesan jaringan saraf, evaluasi model klasifikasi yang lebih mendalam pada objek sawit telah dibuktikan oleh Aryadi dan Suhendar (2024) [12] menggunakan algoritma *Xception* yang diklaim mampu menembus akurasi hingga 99%. Tingginya kapabilitas komputasi tersebut sayangnya masih menyisakan celah fungsionalitas (*research gap*) karena klasifikasi jaringan

hanya direduksi ke dalam bentuk evaluasi biner, yakni kelas "masak" dan "mentah". Padahal, hierarki standar operasional prosedur (SOP) penyortiran di PKS memandatkan kategorisasi yang jauh lebih spesifik, mencakup fraksi "terlalu masak" (fraksi 4 dan 5), yang secara fundamental sangat memengaruhi eskalasi kadar asam lemak bebas (ALB) pada kualitas akhir CPO [13]. Selain itu, arsitektur *Xception* berakurasi tinggi tersebut masih berstatus sebagai model statis dan belum disimulasikan ke dalam lingkungan produksi berbasis aplikasi praktis yang siap guna.

Menyintesis celah literatur dan metodologi dari riset-riset tersebut, penelitian ini memposisikan pembaruan (*novelty*) pada integrasi arsitektur ResNet-50 berkedalaman tinggi dengan implementasi spesifik di fase hilir (rantai sortasi PKS). Penggunaan ResNet-50 dinilai sangat presisi untuk mengatasi masalah degradasi gradien (*vanishing gradient*) pada ekstraksi visual kompleks. Fokus utama penelitian ini merangkai fungsionalitas tiga kelas kematangan dengan *deployment* arsitektur berbasis *framework* web agar secara konkret mampu menjawab hambatan sosio-ekonomi pekebun sekaligus memenuhi validitas audit mutu pabrik pengolahan kelapa sawit.

3 Metode Penelitian

Penelitian ini dilaksanakan secara sistematis mengadaptasi metode pengembangan perangkat lunak iteratif. Keseluruhan tahapan dari perumusan awal hingga implementasi sistem digambarkan pada alur penelitian yang sistematis guna memastikan keandalan hasil yang diperoleh, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1 Alur pelaksanaan penelitian

3.1 Objek dan Lokasi Penelitian

Objek utama dalam penelitian ini adalah citra digital TBS sawit yang diklasifikasikan berdasarkan tingkat kematangannya. Penelitian dilaksanakan dengan mengambil studi kasus operasional di PKS PTPN IV Tanjung Seumantoh, Kabupaten Aceh Tamiang. Lokasi ini dipilih karena proses penyortiran TBS masih dilakukan secara manual, sehingga memerlukan solusi teknologi untuk meningkatkan objektivitas penilaian.

3.2 Prosedur Pengumpulan Data

Data yang digunakan terdiri atas data sekunder dan primer. Data sekunder berupa 1.380 citra TBS yang diperoleh dari repositori terbuka Kaggle.com. Data tersebut kemudian dibagi menjadi 80% data pelatihan (1.104 citra) dan 20% data validasi (276 citra). Sementara itu, data primer sebanyak 75 citra diakuisisi langsung di area sortasi PKS PTPN IV sebagai data pengujian lapangan untuk

memvalidasi kinerja sistem secara *realtime*. Seluruh data mencakup tiga kelas kematangan: belum masak, masak, dan terlalu masak, dengan distribusi yang seimbang untuk menghindari bias model.

Tabel 1 Spesifikasi data sekunder

Atribut Dataset	Keterangan
Sumber Data	Kaggle.com (data sekunder)
Total Citra	1.380 fail (.jpg)
Jumlah Kelas	3 (Belum Masak, Masak, Terlalu Masak)
Distribusi	Seimbang 460 (33,3%) citra per kelas
Pembagian Data	80% Pelatihan, 20% Validasi

Tabel 2 Kualifikasi data primer

Atribut Data Uji	Keterangan
Sumber Data	Sampel TBS di PKS PTPN IV (data lapangan)
Total Citra	75 citra TBS
Jumlah Kelas	Belum Masak (fraksi 00 atau 0) Masak (fraksi 1, 2, atau 3) Terlalu Masak (fraksi 4 atau 5)
Distribusi	Seimbang 25 citra per kelas

3.3 Tahap Prapemrosesan Citra

Sebelum masuk ke tahap pelatihan, citra melalui serangkaian prapemrosesan untuk menstandarkan inputan. Tahapan ini meliputi perubahan ukuran spasial menjadi 224×224 piksel dan normalisasi *zero centering* untuk mempercepat konvergensi *gradient descent*. Guna menangani *noise visual* akibat debu atau variasi cahaya di lokasi pabrik, diterapkan filter median dan *gaussian blur*. Selain itu, teknik augmentasi data seperti rotasi, pergeseran, dan *horizontal flip* diimplementasikan untuk memperkaya variasi data latih secara artifisial dan mencegah *overfitting*.

```

from tensorflow.keras.applications import ResNet50
train_datagen = ImageDataGenerator(
    rotation_range=20,
    width_shift_range=0.1,
    height_shift_range=0.1,
    zoom_range=0.1,
    horizontal_flip=True,
    fill_mode='nearest',
    brightness_range=[0.8, 1.2],
    validation_split=VALIDATION_SPLIT,
    preprocessing_function=preprocess_input
)

```

Gambar 2 Implemenasi augmentasi data

3.4 Arsitektur Model dan *Transfer Learning*

Penelitian ini mengimplementasikan arsitektur ResNet-50 dengan pendekatan *transfer learning* [14] menggunakan bobot yang telah dilatih pada *dataset ImageNet*. Pemanfaatan ResNet-50 didasarkan pada keandalannya dalam mengekstraksi fitur diskriminatif pada citra yang kompleks [15]. Struktur model dimodifikasi dengan membekukan seluruh lapisan dasar untuk mempertahankan fitur visual universal, serta mengganti lapisan klasifikasi asli dengan *Global Average Pooling 2D*, lapisan terhubung penuh (*Dense layer*) 1024 neuron dengan aktivasi ReLU, dan lapisan *Dropout* 0.5. Evaluasi stabilitas arsitektur ini juga akan dikendalikan melalui mekanisme pemantauan *epoch* [16]. Pada lapisan keluaran akhir, digunakan fungsi *Softmax* untuk menghasilkan vektor probabilitas dari ketiga kelas kematangan. Perhitungan probabilitas pada fungsi *Softmax* mengikuti persamaan berikut:

$$Softmax(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^n \exp(x_j)} \quad (1)$$

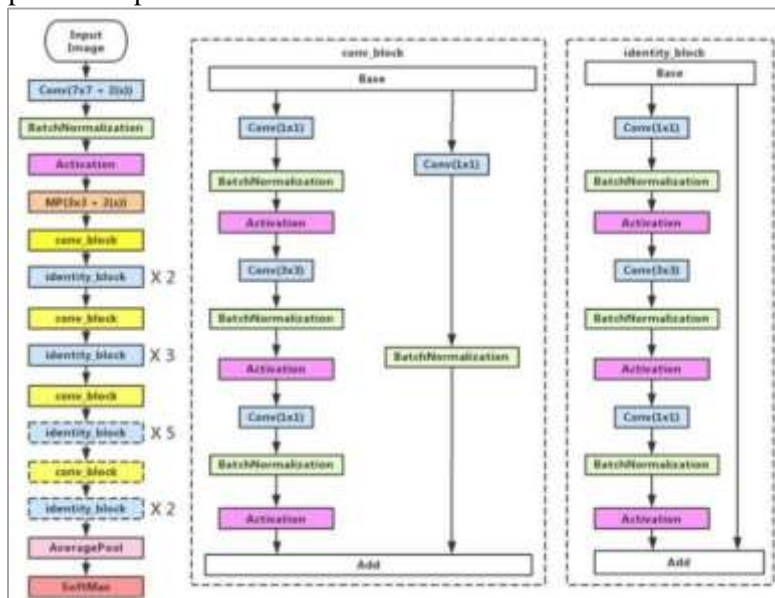
```

x = base_model.output
x = GlobalAveragePooling2D()(x)
x = Dense(1024, activation='relu')(x)
x = Dropout(0.5)(x)
predictions = Dense(NUM_CLASSES, activation='softmax')(x)

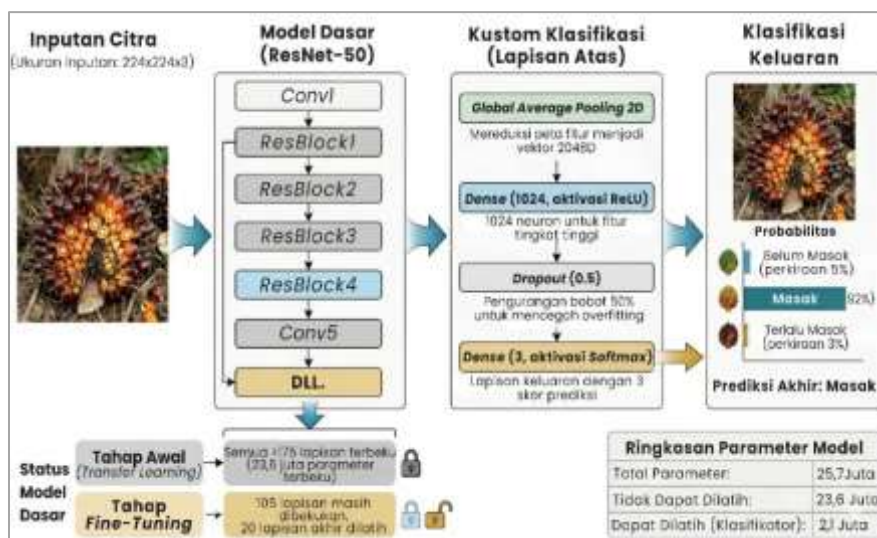
model = Model(inputs=base_model.input, outputs=predictions)
    
```

Gambar 3 Lapisan klasifikasi tambahan

Model dioptimasi menggunakan algoritma Adam dengan *learning rate* sebesar 0,00001 dan fungsi kerugian *Categorical Crossentropy*. Melalui modifikasi *transfer learning*, lapisan klasifikasi asli dibuang dan digantikan oleh blok *Global Average Pooling*, *Dense layer*, dan *Dropout* guna menafsirkan tiga probabilitas kelas kematangan TBS. Visualisasi arsitektur komputasi ResNet-50 yang diusulkan dapat dilihat pada Gambar 4 dan 5.



Gambar 4 Arsitektur ResNet-50



Gambar 5 Implementasi arsitektur ResNet-50

3.5 Metrik Evaluasi Kinerja

Kinerja model diklasifikasikan secara kuantitatif berdasarkan pemetaan pada *confusion matrix*. Metrik utama yang digunakan adalah *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Rumus untuk masing-masing metrik tersebut adalah sebagai berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

Dimana TP adalah *True Positive*, TN adalah *True Negative*, FP adalah *False Positive*, dan FN adalah *False Negative*. Selain metrik di atas, tingkat konsistensi antara hasil deteksi sistem dengan validasi manual petugas pabrik diukur menggunakan analisis *inter-rater reliability* Cohen's Kappa untuk memastikan objektivitas sistem di lapangan.

4 Hasil dan Pembahasan

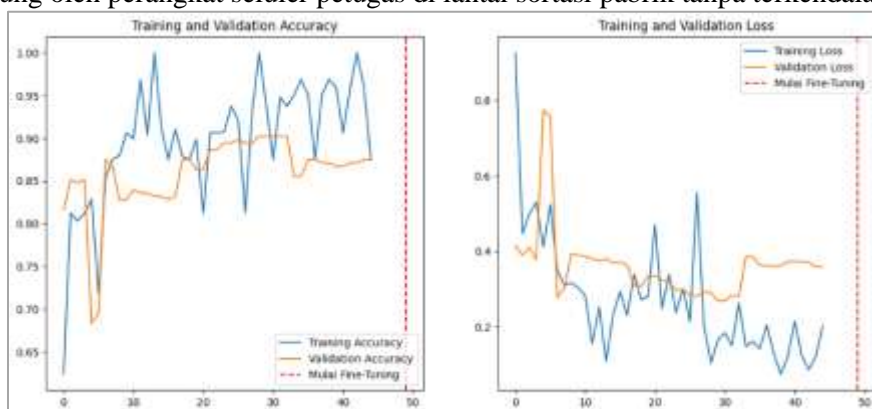
4.1 Analisis Karakteristik Data dan Prapemrosesan

Penerapan arsitektur *deep learning* sangat bergantung pada kualitas dan representasi data latih. Analisis terhadap *dataset* sekunder dari Kaggle menunjukkan bahwa keseimbangan kelas telah tercapai dengan sempurna, yakni masing-masing 460 citra (33,3%) untuk kelas belum masak, masak, dan terlalu masak dari total 1.380 citra. Keseimbangan ini berimplikasi langsung pada pencegahan bias algoritmik, sehingga model tidak memprioritaskan kelas tertentu selama proses pembaruan bobot.

Pada tahap prapemrosesan, standardisasi dimensi menjadi 224×224 piksel dan implementasi *zero centering* terbukti berhasil menstabilkan distribusi data di sekitar angka nol, yang mempercepat konvergensi gradien. Manipulasi geometrik dan kecerahan melalui teknik augmentasi secara efektif memperluas ruang fitur data latih, yang secara langsung menekan risiko terjadinya *overfitting*.

4.2 Hasil Pelatihan Model dan Implementasi Sistem

Pelatihan model ResNet-50 dengan strategi *transfer learning* menunjukkan *learning rate* yang optimal. Penggunaan *learning rate* sebesar 0,00001 dipadukan dengan algoritma optimasi Adam berhasil menjaga pengetahuan bawaan (bobot dasar *ImageNet*) agar tidak rusak akibat pembaruan gradien yang agresif. Mekanisme stabilitas *Early Stopping* yang diterapkan berhasil memutus pelatihan secara otomatis pada *epoch* ke-17 dari total 50 *epoch* maksimum yang direncanakan. Hal ini membuktikan bahwa titik konvergensi optimum—di mana *validation loss* tidak lagi mengalami penurunan signifikan—telah dicapai tanpa model harus menghafal data latih. Model ini kemudian berhasil diintegrasikan ke dalam antarmuka aplikasi web *Flask*. Penggunaan teknologi *tunneling* Ngrok terbukti efektif dalam mengekspos server lokal ke internet, sehingga aplikasi web dapat diakses langsung oleh perangkat seluler petugas di lantai sortasi pabrik tanpa terkendala *firewall*.

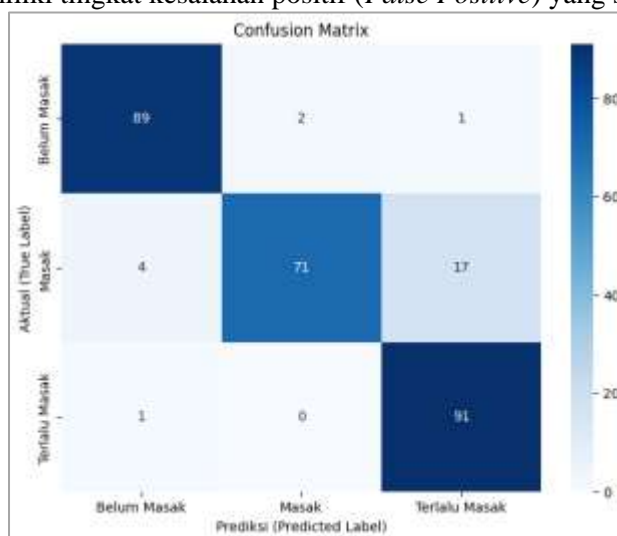


Gambar 6 Kurva *accuracy* dan *loss* pada pelatihan model

4.3 Evaluasi Kinerja Model dan Pengujian Lapangan

Berdasarkan hasil evaluasi pada himpunan data validasi, arsitektur ResNet-50 yang diusulkan mencapai tingkat akurasi keseluruhan sebesar 90,94% dengan *F1-Score* rata-rata sebesar 91%.

Analisis metrik secara spesifik menunjukkan nilai *Precision* mencapai 97% untuk kelas "Masak", yang berarti model memiliki tingkat kesalahan positif (*False Positive*) yang sangat minim.



Gambar 7 Hasil confusion matrix

Tingginya presisi ini penting dalam operasional industri untuk mencegah TBS mentah lolos terdeteksi sebagai TBS masak, yang dapat memicu eskalasi kadar ALB pada CPO. Pada kelas "Belum Masak", model mencatatkan nilai *Recall* 97%, yang mengonfirmasi tingginya sensitivitas algoritma dalam mengidentifikasi TBS pengotor sebelum masuk ke *hopper loading ramp*.

Tabel 3 Nilai evaluasi model

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Data
Belum Masak	95%	97%	96%	92
Masak	97%	77%	86%	92
Terlalu Masak	83%	99%	91%	92
Rata-Rata (<i>Macro Avg</i>)	92%	91%	91%	276

Lebih lanjut, pengujian lapangan secara *realtime* di PKS PTPN IV Tanjung Seumantoh terhadap 42 sampel data primer membuktikan keandalan sistem dalam skenario industri nyata. Dari 42 sampel bongkaran TBS asli tersebut, sistem berhasil mengklasifikasikan 35 citra dengan tingkat keberhasilan 83,33%. Temuan paling krusial dari pengujian ini adalah tercapainya *zero misclassification* (tidak ada prediksi silang yang salah). Sebanyak 7 sampel yang tidak berhasil diklasifikasikan dilabeli sebagai "Objek Tidak Dikenali" karena skor probabilitasnya berada di bawah ambang batas konfidensi 75% yang ditetapkan oleh sistem.

Tabel 4 Ringkasan hasil validitas pengujian lapangan

Kategori Aktual	Total Sampel	Deteksi Benar	Objek Tidak Dikenali (<75%)
Belum Masak	14	13	1
Masak	14	12	2
Terlalu Masak	14	10	4
Total Keseluruhan	42	35	7

Untuk memvalidasi objektivitas tersebut, analisis *inter-rater reliability* menggunakan Cohen's Kappa mencatatkan skor 0,769 (*Substantial Agreement*), yang menegaskan tingginya keselarasan rasionalisasi antara algoritma buatan dan inspeksi visual petugas pabrik yang berpengalaman.

Tabel 5 Hasil uji cohen's kappa

Ratings	Kappa	SE	Lower	Upper
---------	-------	----	-------	-------

Rata-Rata Kappa	0.769			
Validasi Petugas - Hasil Deteksi	0.769	0.073	0.626	0.913

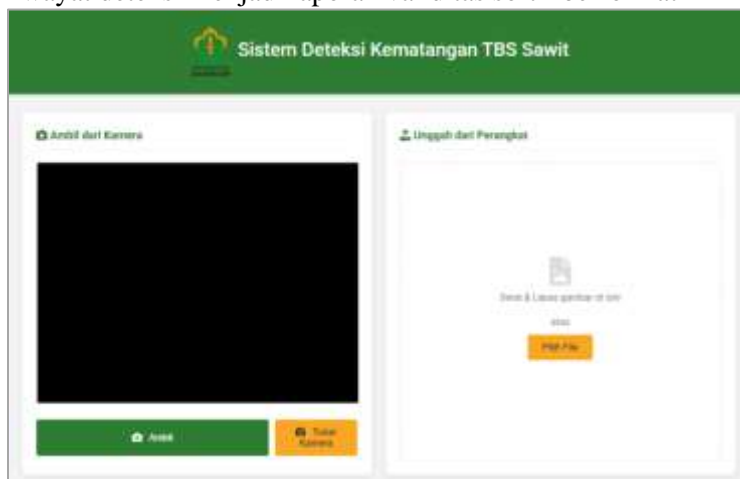
4.4 Pembahasan dan Keunggulan Penelitian

Interpretasi komprehensif terhadap hasil pengujian membuktikan kelayakan implementasi *deep learning* pada fase pascapanen industri kelapa sawit. Dibandingkan dengan riset Aryadi dan Suhendar (2024) yang mengimplementasikan arsitektur Xception terbatas pada klasifikasi biner (masak dan mentah), penelitian ini mendemonstrasikan keunggulan fungsional dengan memetakan deteksi ke dalam tiga kelas agregat. Pemetaan tiga kelas ini selaras dengan regulasi ISO 9000 PKS, yang membuat sistem usulan ini jauh lebih relevan untuk diadopsi langsung dalam audit mutu CPO.

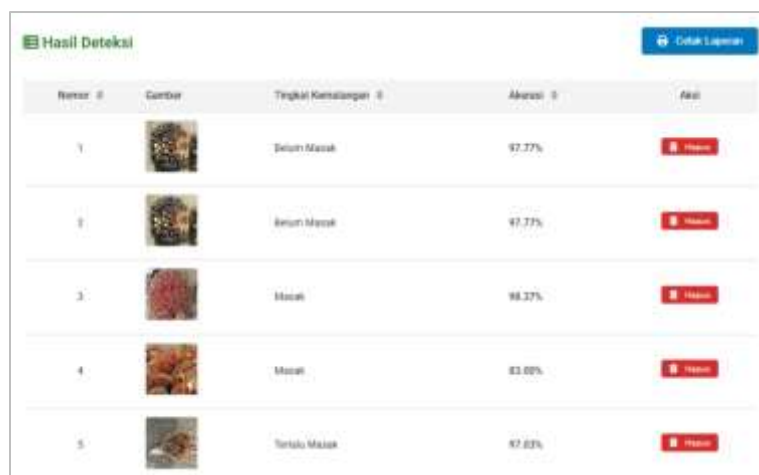
Selain itu, pendekatan operasional riset ini memecahkan kebuntuan ergonomi dari penelitian-penelitian sebelumnya. Model yang ditawarkan oleh Bahri dkk. (2019) dengan CenterNet serta instrumen "Egrek Digital" dari Widodo dkk. (2019) dieksekusi di tingkat perkebunan saat proses panen. Pendekatan hulu tersebut menghadapi oklusi visual dari pelepah dan terhambat oleh daya beli pekebun. Sebaliknya, sistem berbasis ResNet-50 dan *Flask* ini secara spesifik dirancang untuk diimplementasikan di lantai *grading* PKS, sehingga memastikan jarak pandang citra terkontrol dan membebaskan petani dari kewajiban berinvestasi pada instrumen canggih. Keunikan lain yang menjadi kekuatan utama model ini adalah penerapan ambang batas probabilitas 75%, yang mendikte sistem untuk bersikap konservatif: lebih baik menolak memberikan keputusan (menjadi "Objek Tidak Dikenali") daripada meloloskan TBS pengotor akibat prediksi yang meleset. Perilaku preventif inilah yang memastikan konsistensi mutu CPO tetap terjamin dengan ketat.






4.5 Implementasi Sistem

Hilirisasi dari model kecerdasan buatan yang telah dilatih direalisasikan melalui pengembangan antarmuka sistem terintegrasi menggunakan *microframework Flask* [17]. Sistem ini dirancang secara khusus untuk menjembatani interaksi antara algoritma backend ResNet-50 dengan petugas di lantai sortasi pabrik. Pendekatan ini memungkinkan *Flask* beroperasi tidak hanya sebagai *framework web*, tetapi juga sebagai penyedia layanan *Representational State Transfer* (RESTful) API yang andal dan ringan untuk menjembatani model komputasi berat dengan antarmuka klien [18]. Pada implementasi antarmuka utama, desain *frontend* dibangun menggunakan struktur HTML dinamis yang dikombinasikan dengan CSS dan JavaScript untuk menekan beban komputasi di sisi klien [19]. Antarmuka utama ini menyediakan dua mode akuisisi citra yang fleksibel, yakni unggah berkas dari penyimpanan lokal dan tangkapan langsung (*realtime video stream*) menggunakan antarmuka *MediaDevices* API pada kamera [20]. Desain *dashboard* versi desktop ini sangat esensial bagi pengawas pabrik karena memfasilitasi pemantauan hasil klasifikasi, penyaringan probabilitas akurasi, hingga pencetakan riwayat deteksi menjadi laporan validitas sortir berformat PDF.



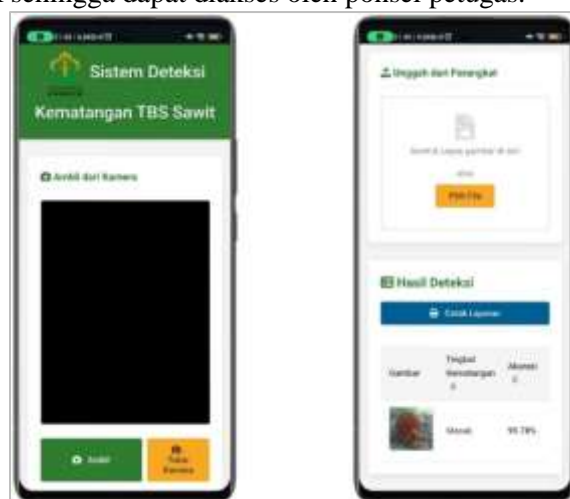
Gambar 8 Antarmuka sistem deteksi kematangan TBS



No	Citra	Tingkat Kematangan	Akurasi	Hasil
1		Belum Masak	97.77%	Hasil
2		Belum Masak	97.77%	Hasil
3		Masak	98.37%	Hasil
4		Masak	83.00%	Hasil
5		Terlalu Masak	97.83%	Hasil

Gambar 9 Tampilan hasil deteksi sistem

Guna menjawab tantangan mobilitas petugas penyortir di lapangan, sistem ini juga dioptimalkan melalui implementasi antarmuka yang responsif untuk layar perangkat seluler. Mengingat petugas sortir diharuskan untuk terus bergerak menginspeksi bongkaran truk di area *hopper loading ramp*, akses nirkabel dan ringkas melalui peramban ponsel cerdas menjadi sangat krusial. Melalui pemanfaatan teknologi *reverse proxy tunneling* dari Ngrok, server *Flask* dapat diekspos secara aman ke jaringan internet publik sehingga dapat diakses oleh ponsel petugas.



Gambar 10 Antarmuka sistem deteksi pada layar ponsel

Pada tampilan versi seluler ini, tata letak elemen antarmuka disesuaikan secara ergonomis agar petugas dapat dengan cepat memotret sampel TBS dengan satu tangan, mengirimkan permintaan HTTP POST, dan langsung menerima respons pembaruan antarmuka berisi label tingkat kematangan dalam hitungan detik. Fleksibilitas ganda pada kedua antarmuka ini memastikan bahwa algoritma komputasi yang dibangun tidak hanya berakhir sebagai model teoritis, melainkan menjadi solusi operasional yang praktis bagi industri pengolahan sawit.

5 Kesimpulan

Penelitian ini membuktikan bahwa implementasi arsitektur *deep learning* ResNet-50 menggunakan strategi *transfer learning* sangat efektif dalam mengoptimalkan objektivitas dan akurasi sortasi kematangan TBS sawit. Berdasarkan hasil evaluasi kuantitatif, model yang dikembangkan berhasil mencapai tingkat akurasi validasi sebesar 90,94% dengan *F1-Score* rata-rata mencapai 91%. Keberhasilan pengklasifikasian citra secara akurat ke dalam tiga kategori standar operasional pabrik (belum masak, masak, dan terlalu masak) membuktikan bahwa jaringan saraf tiruan ini mampu mengekstraksi fitur visual eksokarp sawit dengan presisi tinggi tanpa memihak pada kelas tertentu.

Lebih dari sekadar keberhasilan komputasional, model prediksi ini telah diintegrasikan secara optimal ke dalam antarmuka aplikasi web fungsional berbasis *Flask*, sehingga memungkinkan deteksi secara praktis melalui perangkat seluler. Validasi empiris pada pengujian lapangan secara langsung di PKS mencatatkan tingkat reliabilitas yang solid dengan nilai Cohen's Kappa sebesar 0,769 (*Substantial Agreement*) jika disandingkan dengan justifikasi manual petugas sortir. Selain itu, penetapan nilai ambang batas kepastian sebesar 75% terbukti sukses mendikte sistem untuk bertindak secara konservatif, yang berujung pada nihilnya kesalahan prediksi silang (*zero misclassification*). Secara keseluruhan, inovasi teknologi deteksi ini telah sepenuhnya menjawab tujuan penelitian untuk menghadirkan solusi automasi penyortiran yang objektif, andal, dan siap diimplementasikan untuk menjaga mutu produk industri pengolahan sawit.

Referensi

- [1] P. R. Indonesia, *Undang-Undang Nomor 39 Tahun 2014 tentang Perkebunan*. Jakarta: Sekretariat Negara, 2014.
- [2] M. L. F. Sitorus, E. N. Akoeb, R. Sembiring, dan M. A. Siregar, "Peningkatan Produksi *Crude Palm Oil (CPO)* melalui Kriteria Matang Panen Tandan Buah Segar (TBS) untuk Optimalisasi Pendapatan Perusahaan," *Jurnal Ilmiah Magister Agribisnis*, Vol. 2, No. 1, hlm. 26–32, 2020, DOI: 10.31289/agrisains.v2i1.251.
- [3] F. Rahmadhania, P. Sembiring, dan M. A. Sinaga, "Pengaruh Kematangan Buah Kelapa Sawit Varietas Dxp Bah Lias terhadap Kadar Minyak Sawit Mentah (CPO)," *Jurnal Agro Estate*, Vol. 3, No. 1, hlm. 1–9, 2019, DOI: 10.47199/jae.v3i1.56.
- [4] Z. Bahri, J. Risanto, dan H. Gussyafri, "Pengembangan Sistem *Realtime* Deteksi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit menggunakan Metode *Centernet* berbasis *Mobile Android*," dalam *Grant Riset Sawit 2024 Ringkasan Penelitian*, Badan Pengelola Dana Perkebunan Kelapa Sawit, 2024, hlm. 155–156.
- [5] E. Widodo, Widyastuti, R. Widyaningrum, B. Al Kindhi, R. S. Dewi, dan F. N. Setiowati, "Egrek Digital: Peningkatan Efisiensi Panen dan Substitusi Impor," dalam *Grant Riset Sawit 2024 Ringkasan Penelitian*, Badan Pengelola Dana Perkebunan Kelapa Sawit, 2024, hlm. 99–100.
- [6] J. Zulkarnain, Kusriani, dan T. Hidayat, "Klasifikasi Tingkat Kematangan Tandan Buah Segar Kelapa Sawit menggunakan Pendekatan *Deep Learning*," *JST (Jurnal Sains dan Teknologi)*, Vol. 12, No. 3, hlm. 748–758, 2024, DOI: 10.23887/jstundiksha.v12i3.59140.
- [7] S. Ashari, G. J. Yanris, dan I. Purnama, "*Oil Palm Fruit Ripeness Detection using Deep Learning*," *Sinkron: Jurnal dan Penelitian Teknik Informatika*, Vol. 6, No. 2, hlm. 649–656, 2022, DOI: 10.33395/sinkron.v7i2.11420.
- [8] R. Triyogi, R. Magdalena, dan B. Hidayat, "Mendeteksi Kematangan Buah Kelapa Sawit menggunakan *Convolutional Neural Network Deep Learning*," *Jurnal Nasional Sains dan Teknik*, Vol. 1, No. 1, hlm. 22–27, 2023, DOI: 10.25124/jnst.v1i1.6732.
- [9] M. Minarni, R. Salumbae, dan Z. Hasbi, "Implementasi Jaringan Syaraf Tiruan (JST) dan Pengolahan Citra untuk Klasifikasi Kematangan TBS Kelapa Sawit," *Indonesian Physics Communication*, Vol. 15, No. 1, hlm. 36–45, 2018.
- [10] M. A. Syahira, M. Khoiriah, dan R. S. Harahap, "Rancang Bangun Alat Pendeteksi Kematangan Buah Sawit dengan menggunakan Metode *Image Processing* berdasarkan Komposisi Warna," *Jurnal Garuda Pengabdian Kepada Masyarakat*, Vol. 1, No. 2, hlm. 78–87, 2023, DOI: 10.55537/gabdimas.v1i2.827.
- [11] M. Andri, Jasmir, dan W. Riyadi, "Rancang Bangun *Prototype* Sortir Buah Kelapa Sawit berdasarkan Tingkat Kematangan berbasis Arduino Uno," *Jurnal Informatika dan Rekayasa Komputer (JAKAKOM)*, Vol. 3, No. 1, hlm. 501–510, 2023, DOI: 10.33998/jakakom.2023.3.1.812.
- [12] I. Aryadi dan A. Suhendar, "Implementasi Arsitektur *Xception* dalam menentukan Kematangan Tandan Buah Segar Kelapa Sawit," *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, Vol. 13, No. 3, hlm. 2235–2247, 2024, DOI: 10.35889/jutisi.v13i3.2337.

- [13] K. P. R. Indonesia, *Peraturan Menteri Pertanian Nomor 13 Tahun 2024 tentang Pembelian Tandan Buah Segar Kelapa Sawit Produksi Pekebun Mitra*. Jakarta: Kementerian Pertanian Republik Indonesia, 2024.
- [14] E. A. M. Iqbal, “Hybrid Model Transfer Learning ResNet50 dengan Support Vector Machine untuk Deteksi Masker pada Image Wajah,” 2023.
- [15] M. A. N. Hidayat, “Convolutional Neural Network pada Identifikasi Varian Tanaman Anggur menggunakan Resnet-50,” *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, Vol. 10, No. 3, hlm. 61–70, 2023, DOI: 10.35957/jatisi.v10i3.4789.
- [16] F. Nashrullah, S. A. Wibowo, dan G. Budiman, “Investigasi Parameter Epoch pada Arsitektur Resnet-50 untuk Klasifikasi Pornografi,” *Journal of Computer, Electronic, and Telecommunication*, Vol. 1, No. 1, hlm. 1–8, 2020, DOI: 10.52435/complete.v1i1.51.
- [17] D. F. Ningtyas dan N. Setiyawati, “Implementasi *Flask Framework* pada Pembangunan Aplikasi *Purchasing Approval Request*,” *Jurnal Janitra Informatika dan Sistem Informasi*, Vol. 1, No. 1, hlm. 19–34, 2021, DOI: 10.25008/janitra.v1i1.120.
- [18] M. G. L. Putra dan M. I. A. Putera, “Analisis Perbandingan Metode SOAP dan REST yang digunakan pada *Framework Flask* untuk membangun *Web Service*,” *Scan: Jurnal Teknologi Informasi dan Komunikasi*, Vol. 14, No. 2, hlm. 1–7, 2019, DOI: 10.33005/scan.v14i2.1480.
- [19] G. N. Elwirehardja, J. S. Prayoga, dan Suharjito, “*Oil Palm Fresh Fruit Bunch Ripeness Classification on Mobile Devices using Deep Learning Approaches*,” *Comput. Electron. Agric.*, Vol. 188, hlm. 106359, 2021, DOI: 10.1016/j.compag.2021.106359.
- [20] J. W. Lai, H. R. Ramli, L. I. Ismail, dan W. Z. W. Hasan, “*Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch based on YOLOv4*,” *IEEE Access*, Vol. 10, hlm. 95763–95770, 2022, DOI: 10.1109/ACCESS.2022.3204762.