

IMPLEMENTASI MODEL EFFICIENTNET-B5 DENGAN TRANSFER LEARNING UNTUK KLASIFIKASI TINGKAT ROASTING BIJI KOPI BERBASIS CITRA

Jody Kalim, Nenden Siti Fatonah, Riya Widayanti, Rahmat Budiarsa

Teknik Informatika, Universitas Esa Unggul
Jalan Arjuna Utara No. 9, Kebon Jeruk, Jakarta Barat
Jodykalim16@gmail.com

ABSTRAK

Kopi merupakan komoditas strategis yang berkontribusi besar terhadap perekonomian nasional Indonesia, dengan produksi mencapai 810.000 ton pada tahun 2024. Kualitas produk kopi sangat ditentukan oleh proses *roasting* yang menghasilkan empat kategori tingkat kematangan dengan karakteristik visual berbeda. Namun, penilaian tingkat *roasting* secara manual rentan terhadap inkonsistensi akibat ketergantungan pada persepsi visual subjektif operator, sehingga berpotensi menurunkan konsistensi mutu dan daya saing produk kopi di pasar. Penelitian ini bertujuan mengembangkan sistem klasifikasi tingkat *roasting* biji kopi berbasis citra secara otomatis dan objektif menggunakan arsitektur *EfficientNet-B5* dengan pendekatan *Transfer Learning*. Dataset yang digunakan berjumlah 1.600 citra biji kopi dari Kaggle yang terdistribusi seimbang dalam empat kategori, yaitu *Green*, *Light*, *Medium*, dan *Dark*, dengan pembagian data 60% latih, 15% validasi, dan 25% uji. Model dikembangkan menggunakan bobot awal *ImageNet*, pembekuan 150 layer awal, *optimizer Adam*, serta lapisan klasifikasi tambahan yang terdiri atas *GlobalAveragePooling2D*, *BatchNormalization*, *Dense*, dan *Dropout*. Hasil evaluasi menunjukkan akurasi pengujian sebesar 98,68% dengan rata-rata *Precision*, *Recall*, dan *F1-Score* sebesar 0,98, mencerminkan kemampuan generalisasi yang tinggi. Eksperimen komparatif membuktikan bahwa *Transfer Learning* bersifat esensial, karena model tanpa bobot *pre-trained* mengalami kegagalan konvergensi dengan akurasi hanya 26%. Model juga diintegrasikan ke dalam prototipe aplikasi web berbasis *Streamlit* untuk inferensi citra secara *real-time*.

Kata kunci : *Deep Learning, Klasifikasi Citra, Transfer Learning, Roasting Biji kopi, EfficientNet-B5.*

1. PENDAHULUAN

Kopi merupakan komoditas strategis yang memegang peranan penting dalam kehidupan sosial-ekonomi masyarakat Indonesia. Minuman ini tidak hanya menjadi bagian dari budaya keseharian, tetapi juga berkontribusi signifikan terhadap pertumbuhan ekonomi nasional [1]. Tren konsumsi yang terus meningkat mendorong ekspansi kapasitas produksi secara berkelanjutan, di mana catatan terbaru menunjukkan produksi kopi Indonesia mencapai 810.000 ton pada tahun 2024, meningkat dari 750.000 ton pada tahun sebelumnya dan menjadi angka tertinggi sepanjang periode 2014–2024 [2].

Di tengah perkembangan industri yang semakin kompetitif, kualitas aroma dan cita rasa tetap menjadi penentu utama nilai sebuah produk kopi. Parameter kualitas tersebut sangat dipengaruhi oleh proses *roasting*, yakni tahapan pemanggangan biji kopi hijau (*green bean*) yang memicu serangkaian reaksi fisik dan kimia, meliputi penguapan kandungan air, pengembangan struktur biji, penurunan berat hingga 20%, serta pembentukan senyawa aroma melalui transformasi unsur gula menjadi karbon dioksida [3]. Variasi dalam pelaksanaan proses ini menghasilkan empat kategori tingkat *roasting*, yaitu *Unroasted*, *Light*, *Medium*, dan *Dark*, yang masing-masing menghasilkan profil rasa yang khas dan dapat dibedakan secara visual melalui perubahan warna biji dari hijau hingga cokelat gelap.

Permasalahan mendasar yang dihadapi industri kopi saat ini adalah ketergantungan pada metode

penilaian tingkat *roasting* secara manual yang bersifat subjektif. Proses identifikasi berbasis pengamatan visual operator rentan terhadap inkonsistensi penilaian akibat kelelahan, perbedaan persepsi warna antarindividu, serta keterbatasan kemampuan membedakan gradasi visual yang halus antarkelas *roasting*, khususnya antara *Medium* dan *Dark*. Kondisi tersebut berpotensi menghasilkan kesalahan klasifikasi yang berdampak langsung pada ketidakonsistenan mutu produk dan penurunan kepuasan konsumen.

Guna mengatasi permasalahan tersebut, perkembangan teknologi kecerdasan buatan (*artificial intelligence*) membuka peluang penerapan sistem klasifikasi otomatis berbasis citra. *Deep Learning* sebagai cabang lanjutan dari *Machine Learning* mampu mengenali pola visual kompleks secara hierarkis melalui struktur jaringan berlapis tanpa bergantung pada ekstraksi fitur manual [4], [5]. Dalam domain pengolahan citra digital, *Convolutional Neural Network* (CNN) telah terbukti efektif mengekstraksi fitur warna, tekstur, dan pola spasial secara bertahap melalui mekanisme filter konvolusi berbobot [6], [7]. Untuk mengatasi tantangan efisiensi komputasi sekaligus mempertahankan akurasi tinggi, arsitektur *EfficientNet* dikembangkan melalui pendekatan *compound scaling* yang mengoptimalkan kedalaman, lebar jaringan, dan resolusi input secara simultan [8], [9].

Penelitian ini bertujuan mengembangkan dan mengimplementasikan model *Deep Learning* berbasis

arsitektur *EfficientNet-B5* dengan pendekatan *Transfer Learning* menggunakan bobot awal *ImageNet* untuk klasifikasi empat tingkat *roasting* biji kopi berbasis citra secara otomatis dan objektif. Pendekatan *Transfer Learning* dipilih untuk mengatasi keterbatasan jumlah data latih sekaligus mempercepat konvergensi model [10]. Kinerja model dievaluasi menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score* guna memastikan reliabilitas klasifikasi pada setiap kategori *roasting* [11].

2. TINJAUAN PUSTAKA

2.1. Dasar Teori Kopi

Kopi merupakan komoditas pertanian bernilai ekonomi tinggi dan memiliki peran kuat dalam budaya masyarakat Indonesia [1]. Kualitas rasa, aroma, dan warna kopi sangat dipengaruhi oleh tahapan pengolahan, khususnya proses *roasting* yang menentukan karakter akhir biji kopi. *Roasting* mentransformasi biji kopi hijau menjadi biji berwarna coklat melalui pemanasan yang memicu perubahan fisik dan kimia, termasuk penguapan air dan pembentukan senyawa aroma [3]. Tingkat *roasting* secara umum terbagi menjadi *Unroasted*, *Light Roast*, *Medium Roast*, dan *Dark Roast* yang dibedakan berdasarkan warna, tingkat kematangan, serta karakter rasa. Ciri visual tersebut menjadi dasar utama dalam klasifikasi tingkat *roasting* biji kopi.

2.2. Pengolahan Citra Digital

Pengolahan citra digital merupakan teknik pemrosesan gambar menggunakan algoritma komputer untuk meningkatkan kualitas citra dan mengekstraksi informasi visual yang relevan. Dalam klasifikasi tingkat *roasting* biji kopi, pengolahan citra digunakan untuk membedakan karakteristik warna dan tekstur antar kelas *roasting*. Tahapan utama meliputi *resizing* untuk menyeragamkan ukuran citra, normalisasi nilai piksel, augmentasi data untuk meningkatkan variasi, serta ekstraksi fitur visual [12]. Penerapan tahapan tersebut menghasilkan input citra yang lebih stabil dan representatif bagi model *deep learning*.

2.3. Kecerdasan Buatan, Machine Learning, dan Deep Learning


Kecerdasan buatan merupakan cabang ilmu komputer yang memungkinkan mesin menjalankan tugas yang berkaitan dengan pembelajaran dan pengambilan keputusan [4]. *Machine Learning* sebagai bagian dari AI mempelajari pola dari data untuk menghasilkan prediksi pada data baru [13]. *Deep Learning* merupakan pengembangan lanjutan dari *Machine Learning* yang memanfaatkan jaringan saraf tiruan berlapis untuk mengenali pola kompleks [5], [14]. Pendekatan ini efektif dalam pengolahan citra karena mampu mengenali bentuk, warna, dan tekstur secara hierarkis [6], [15]. Oleh sebab itu, *Deep Learning* banyak diterapkan pada klasifikasi citra biji kopi berdasarkan tingkat *roasting*.

2.4. Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan arsitektur *Deep Learning* yang dirancang untuk memproses data berbentuk grid seperti citra [16]. CNN mampu mengekstraksi fitur visual seperti tepi, warna, dan tekstur melalui lapisan konvolusi yang dilengkapi bobot dan bias [7], [17]. Struktur CNN yang terdiri atas *convolutional*, *activation*, *pooling*, dan *fully connected layer* memungkinkan ekstraksi pola visual secara bertahap sehingga sesuai untuk klasifikasi tingkat *roasting* biji kopi dengan perbedaan visual halus [6].


2.5. Architektur EfficientNet

EfficientNet merupakan arsitektur CNN yang dikembangkan oleh Tan dan Le (2019) dengan tujuan meningkatkan efisiensi dan performa klasifikasi citra [8]. Arsitektur ini menerapkan *pendekatan compound scaling* yang menyeimbangkan kedalaman jaringan, lebar jaringan, dan resolusi input secara simultan. Pendekatan tersebut menghasilkan model yang efisien dalam penggunaan parameter serta stabil dalam performa [17], [18].



Gambar 1. Perbandingan strategi model scaling

Selain strategi *scaling*, EfficientNet dibangun menggunakan blok *MBConv* yang dipadukan dengan mekanisme *Squeeze-and-Excitation* untuk memprioritaskan fitur penting sehingga EfficientNet sesuai citra dengan tekstur kompleks seperti biji kopi.



Gambar 2. Struktur blok MBConv dengan Squeeze-and-Excitation

2.6. Fungsi Aktivasi Swish

Fungsi aktivasi Swish merupakan komponen dalam arsitektur EfficientNet yang menggantikan penggunaan ReLU konvensional [19]. Fungsi ini dirumuskan sebagai berikut.

$$f(x) = x \cdot \sigma(\beta x) \quad (1)$$

Keterangan:

$f(x)$: keluaran fungsi aktivasi Swish


x : nilai input neuron

$\sigma(\cdot)$: fungsi sigmoid

β : parameter pengendali non-linearitas

$\sigma(\beta x)$: nilai sigmoid dari hasil perkalian β dan x

Fungsi ini memiliki karakteristik non-monotonik serta kurva yang halus. Sifat tersebut menjaga aliran gradien pada nilai input negatif dan mendukung proses optimasi jaringan yang lebih stabil. Swish juga mengurangi risiko neuron berhenti belajar dibandingkan ReLU. Penerapan fungsi ini terbukti meningkatkan performa klasifikasi citra secara empiris.



Gambar 3. Perbandingan grafik fungsi aktivasi ReLU dan Swish


2.7. EfficientNet-B5

EfficientNet-B5 merupakan varian EfficientNet yang diperbesar skalanya menggunakan koefisien majemuk $\phi = 5$ [8]. Model ini memiliki sekitar 30 juta parameter dan dirancang untuk resolusi input 456×456 piksel, namun penelitian ini menggunakan penyesuaian resolusi menjadi 224×224 piksel untuk efisiensi komputasi. Struktur jaringan yang lebih dalam dan lebar memberikan kapasitas ekstraksi fitur visual yang kuat meskipun resolusi input diturunkan. EfficientNet-B5 dipilih karena menawarkan keseimbangan antara akurasi tinggi dan penggunaan sumber daya yang efisien [9], [18]. Model ini dimanfaatkan sebagai *feature extractor* dengan bobot awal *ImageNet* dan disesuaikan melalui *fine-tuning*.

2.8. Transfer Learning

Transfer Learning merupakan pendekatan yang memanfaatkan model terlatih untuk menyelesaikan permasalahan baru yang memiliki kemiripan karakteristik data [10]. Pendekatan ini efektif pada kondisi dataset terbatas karena model telah memiliki representasi fitur umum dari dataset besar seperti *ImageNet* [20]. *Transfer Learning* dilakukan melalui dua strategi utama, yaitu *feature extraction* dan *fine-tuning*, bergantung pada tingkat penyesuaian model terhadap data target [21]. Penerapan strategi ini

meningkatkan efisiensi pelatihan serta performa klasifikasi. Pendekatan tersebut sesuai untuk klasifikasi citra biji kopi yang memiliki keterbatasan data teranotasi.



(a) Traditional Machine Learning (b) Transfer Learning
Gambar 4. Perbandingan (a) traditional machine learning, (b) transfer learning

2.9. Penelitian Terkait

Berbagai penelitian terdahulu telah menerapkan CNN dan EfficientNet dalam klasifikasi citra pada domain agrikultur, medis, dan kopi. Model ringan seperti MobileNet menunjukkan performa tinggi namun memiliki keterbatasan dalam menangani kompleksitas visual yang lebih dalam [22]. Penelitian lain membuktikan EfficientNet memiliki keseimbangan antara efisiensi dan akurasi meskipun menggunakan varian yang lebih rendah seperti B0 atau B1 [23], [24]. Penggunaan EfficientNet-B5 pada klasifikasi tingkat *roasting* biji kopi masih jarang dilakukan, terutama pada kondisi resolusi input rendah.

3. METODE PENELITIAN

3.1. Rancangan Penelitian

Penelitian ini menggunakan kerangka kerja *Cross-Industry Standard Process for Data Mining* (CRISP-DM) guna memastikan alur penelitian berjalan sistematis dan terstruktur. Alur penelitian terdiri dari enam tahap utama, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modelling*, *Evaluation*, dan *Deployment*. Penelitian ini diawali dengan *Business Understanding* untuk mengatasi subjektivitas penilaian manual tingkat *roasting* melalui klasifikasi otomatis berbasis citra.

Data Understanding dilakukan dengan mengumpulkan 1.600 citra biji kopi dari Kaggle yang terbagi seimbang dalam empat kelas, dilanjutkan *Data Preparation* berupa pembagian data sebanyak 60% data latih, 15% data validasi, dan 25% data uji, *preprocessing*, *resizing* 224×224 piksel, serta augmentasi data [25]. Tahap *Modelling* menerapkan *transfer learning* menggunakan EfficientNet-B5 dengan pembekuan layer awal dan penyesuaian lapisan akhir, kemudian dievaluasi menggunakan metrik akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix* [12]. Tahap *Deployment* diwujudkan melalui implementasi model pada prototipe aplikasi web berbasis Streamlit sebagai *proof of concept* untuk visualisasi hasil klasifikasi.

3.2. Perancangan Arsitektur Model

Arsitektur model dirancang menggunakan pendekatan *transfer learning* dengan memanfaatkan EfficientNet-B5 sebagai *base model* karena efisiensi parameter dan performanya yang tinggi dalam pengolahan citra [8]. Struktur model terdiri atas dua komponen utama, yaitu *base model* EfficientNet-B5 dan *custom classification head* yang disesuaikan untuk klasifikasi empat tingkat *roasting* biji kopi.

3.3. Base Model: EfficientNet-B5

EfficientNet-B5 digunakan dengan bobot awal *ImageNet* dan fungsi aktivasi Swish. Model dikonfigurasi menggunakan input berukuran $224 \times 224 \times 3$, *include_top* diset *False*, serta 150 layer awal dibekukan untuk mempertahankan representasi fitur umum. Model dikompilasi menggunakan *optimizer* Adam dengan *learning rate* 0.0001 dan fungsi loss *categorical crossentropy*. Proses pelatihan dilakukan selama 30 epoch dengan batch size 32 serta callback *EarlyStopping* dan *ReduceLROnPlateau* untuk menjaga stabilitas pelatihan.

Tabel 1. Konfigurasi Parameter Model

Komponen	Konfigurasi
Base Model	EfficientNet-B5 (<i>pretrained on ImageNet</i>)
Input Shape	(224,224,3)
Frozen Layers	150
Optimizer	Adam (lr=0.0001)
Loss Function	Categorical Crossentropy
Epochs	30
Batch Size	32
Callbacks	EarlyStopping, ReduceLROnPlateau

3.4. Custom Classification Head

Custom classification head ditambahkan di atas *base model* untuk menyesuaikan tugas klasifikasi empat kelas *roasting*. Rangkaian layer meliputi *GlobalAveragePooling2D*, *BatchNormalization*, *Dense*, dan *Dropout* untuk meningkatkan generalisasi model. Fungsi aktivasi ReLU digunakan pada layer *dense* tambahan, sedangkan *Softmax* diterapkan pada output layer untuk menghasilkan distribusi probabilitas antar kelas. Kombinasi arsitektur ini dirancang agar model mampu mengekstraksi fitur warna dan tekstur biji kopi secara optimal.

3.5. Skenario Pengujian dan Evaluasi

Evaluasi model dilakukan menggunakan data uji terpisah melalui tiga pendekatan utama, yaitu analisis kurva pembelajaran, *confusion matrix*, dan perhitungan metrik evaluasi. Pendekatan ini bertujuan menilai stabilitas pelatihan, kemampuan generalisasi, serta ketepatan prediksi model terhadap setiap kelas *roasting*.

3.6. Analisis Kurva Pembelajaran

Analisis kurva pembelajaran dilakukan dengan memantau perubahan nilai *accuracy* dan *loss* pada data *training* dan *validation* di setiap epoch. Pola grafik digunakan untuk mengidentifikasi kondisi *overfitting*, *underfitting*, atau *good fit* berdasarkan keselarasan performa antara data latih dan validasi.

3.7. Confusion Matrix

Confusion matrix digunakan untuk memetakan hasil prediksi model ke dalam empat kategori, yaitu *True Positive*, *True Negative*, *False Positive*, dan *False Negative*. Analisis ini memberikan gambaran detail mengenai kesalahan klasifikasi antar kelas *roasting* dan distribusi prediksi model.

3.8. Metrik Evaluasi

Kinerja model diukur secara kuantitatif menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. *Accuracy* menunjukkan persentase prediksi benar secara keseluruhan, *precision* mengukur ketepatan prediksi kelas tertentu, *recall* menilai kemampuan model dalam mengenali kelas yang relevan, sedangkan *F1-score* memberikan ukuran harmonik antara *precision* dan *recall*.

3.9. Lingkungan Pengembangan

Aplikasi dikembangkan menggunakan *framework* Streamlit berbasis Python untuk membangun antarmuka interaktif secara cepat pada lingkungan lokal. Implementasi dijalankan pada perangkat dengan spesifikasi AMD Ryzen 7 7840U, RAM 16 GB, dan GPU terintegrasi Radeon 780M. Lingkungan ini dipilih untuk memastikan proses inferensi dan visualisasi hasil klasifikasi berjalan lancar saat demonstrasi.


4. HASIL DAN PEMBAHASAN

4.1. Hasil Pelatihan Model


Pelatihan model dilakukan menggunakan pendekatan *transfer learning* dengan arsitektur EfficientNet-B5 dan bobot awal dari *ImageNet*, disertai augmentasi data untuk meningkatkan variasi dan kemampuan generalisasi. Proses *fine-tuning* dilakukan dengan membekukan hingga 150 layer awal guna mempertahankan fitur visual dasar, kemudian menambahkan beberapa lapisan akhir untuk klasifikasi empat tingkat *roasting* biji kopi. Model dilatih selama 30 epoch menggunakan *optimizer* Adam dengan *learning rate* 0,0001 dan fungsi loss *categorical crossentropy*, serta didukung mekanisme *early stopping* dan *reduce learning rate on plateau* untuk menjaga stabilitas pelatihan dan mencegah *overfitting*.

Visualisasi hasil pelatihan pada Gambar 5 menunjukkan peningkatan akurasi *training* dan *validation* yang konsisten hingga mendekati 95% dan kemudian stabil, dengan selisih yang relatif kecil sehingga mencerminkan kemampuan generalisasi yang baik. Grafik *loss* memperlihatkan penurunan signifikan pada fase awal dan kemudian stabil tanpa

kenaikan kembali yang menandakan tidak terjadinya *overfitting*. Pola ini mengonfirmasi bahwa EfficientNet-B5 mampu mempelajari pola visual citra biji kopi secara efektif dan stabil meskipun dataset yang digunakan terbatas.



Gambar 5. Visualisasi grafik training and validation (a) accuracy



Gambar 6. Visualisasi grafik training and validation (b) loss

4.2. Evaluasi Model


Setelah proses pelatihan selesai, model dievaluasi menggunakan data uji (test set) yang terdiri dari 400 citra biji kopi, dengan masing-masing kelas *Green*, *Light*, *Medium*, dan *Dark* diwakili secara seimbang. Evaluasi dilakukan untuk mengukur kemampuan generalisasi model dalam mengklasifikasikan data yang belum pernah dilihat sebelumnya, dengan mengacu pada metrik akurasi, *loss*, *Confusion Matrix*, serta *classification report*.

Tabel 2. Ringkasan Performa Model Akhir

Subset Data	Accuracy	Loss
Training (Epoch 30)	86.55 %	0.35
Validation (Epoch 30)	98.66 %	0.05
Testing	98.68 %	0.05*

Keterangan : (*) Nilai loss pengujian diestimasi berdasarkan nilai loss validasi terakhir karena tingkat akurasi yang identik.

Ringkasan performa model akhir ditampilkan pada Tabel 2, yang menunjukkan bahwa model mencapai akurasi sebesar 86.55% pada data *training*, 98.66% pada data *validation*, dan 98.68% pada data *testing*. Nilai *loss* pada data *validation* dan *testing* berada pada kisaran 0.05, yang mengindikasikan tingkat kesalahan prediksi yang sangat rendah. Perbedaan antara akurasi *training* dan *validation* dapat dijelaskan oleh penerapan augmentasi data serta penggunaan *Dropout* selama pelatihan, yang membuat model lebih *robust* dan tidak menghafal data latih.



Gambar 7. *Confusion matrix* hasil klasifikasi tingkat roasting

Evaluasi lebih lanjut dilakukan menggunakan *Confusion Matrix* yang ditampilkan pada Gambar 7. Hasil *Confusion Matrix* menunjukkan bahwa dari 400 data uji, model berhasil melakukan prediksi benar pada 393 citra. Kelas *Light* dapat dikenali secara sempurna tanpa adanya kesalahan klasifikasi. Kesalahan minor terjadi pada kelas *Green*, di mana satu citra diprediksi sebagai *Light*, yang kemungkinan disebabkan oleh variasi pencahayaan sehingga warna biji kopi tampak mulai menguning. Selain itu, terdapat sedikit kebingungan antara kelas *Medium* dan *Dark*, masing-masing sebanyak tiga citra yang saling tertukar. Kondisi ini dapat dimaklumi karena kedua kelas berada pada gradasi warna cokelat yang berdekatan dan memiliki karakteristik visual yang relatif mirip. Meskipun demikian, tidak ditemukan kesalahan klasifikasi ekstrem, seperti *Green* yang diprediksi sebagai *Dark*.

Tabel 3. Hasil *Classification Report*

Kategori Kelas	Precision	Recall	F1-Score
Dark	0.97	0.97	0.97
Green	1.00	0.99	0.99
Light	0.99	1.00	1.00
Medium	0.97	0.97	0.97
Rata-Rata	0.98	0.98	0.98
Akurasi	0.98		

Analisis *classification report* pada Tabel 3 menunjukkan bahwa model memiliki performa yang stabil dengan rata-rata *Precision*, *Recall*, dan *F1-Score* sebesar 0,98, mencerminkan keseimbangan kinerja tanpa bias terhadap kelas tertentu. Kelas *Light* menjadi kategori yang paling mudah dikenali dengan nilai *Recall* dan *F1-Score* mencapai 1,00, sementara kelas *Medium* dan *Dark* memiliki metrik sedikit lebih rendah (0,97) akibat kemiripan karakteristik visual pada kondisi pencahayaan tertentu. Kelas *Green* juga menunjukkan kinerja sangat baik dengan presisi 1,00 dan *Recall* 0,99. Hasil ini menegaskan bahwa EfficientNet-B5 berbasis *transfer learning* memiliki reliabilitas dan akurasi tinggi untuk klasifikasi tingkat *roasting* biji kopi berbasis citra.


4.3. Analisis Efektivitas Transfer Learning

Untuk memvalidasi efektivitas penggunaan *Transfer Learning* pada penelitian ini, dilakukan eksperimen pembandingan dengan melatih arsitektur EfficientNet-B5 dari awal tanpa menggunakan bobot *pre-trained ImageNet*. Model pembandingan tersebut dilatih menggunakan dataset, skema pembagian data, serta konfigurasi *hyperparameter* yang sama persis dengan model utama. Pendekatan ini bertujuan memastikan bahwa perbedaan performa yang dihasilkan benar-benar disebabkan oleh penggunaan *Transfer Learning*, bukan oleh faktor lain.

Tabel 4. Perbandingan Performa Model


Metode	Akurasi Training	Akurasi Validasi	Akurasi Testing	Kesimpulan
Tanpa Transfer Learning	35.05 %	25.45 %	26.04 %	Model Gagal (Underfitting)
Dengan Transfer Learning	86.55%	98.66 %	98.68 %	Model Optimal

Hasil perbandingan performa kedua model disajikan pada Tabel 4. Model tanpa *Transfer Learning* menunjukkan performa yang sangat rendah dengan akurasi pengujian hanya sebesar 26.04%. Mengingat dataset terdiri dari empat kelas yang terdistribusi secara seimbang, nilai akurasi tersebut mengindikasikan bahwa model gagal mempelajari pola visual citra dan cenderung melakukan prediksi secara acak (*random guessing*). Sebaliknya, model dengan *Transfer Learning* mampu mencapai akurasi pengujian sebesar 98.68% dengan nilai *loss* yang sangat rendah, yang menunjukkan bahwa inisialisasi bobot awal dari *ImageNet* berperan krusial dalam mempercepat konvergensi dan meningkatkan kemampuan klasifikasi model.



Gambar 8. Grafik akurasi model tanpa transfer learning

Kegagalan model tanpa *Transfer Learning* semakin diperjelas melalui analisis grafik pelatihan dan *Confusion Matrix* yang ditunjukkan pada Gambar 8 dan Gambar 9. Grafik akurasi menunjukkan bahwa nilai akurasi validasi stagnan di kisaran 25% sepanjang proses pelatihan, yang menandakan terjadinya kegagalan konvergensi. Kondisi ini terjadi karena EfficientNet-B5 memiliki jumlah parameter yang sangat besar, sehingga membutuhkan dataset dalam jumlah jauh lebih besar untuk dapat dilatih dari nol secara efektif. Dengan jumlah data yang terbatas, model tidak mampu menyesuaikan bobot secara optimal dan terjebak pada solusi yang tidak informatif.



Gambar 9. Confusion matrix model tanpa transfer learning


Fenomena tersebut diperkuat oleh hasil *Confusion Matrix*, yang memperlihatkan bahwa model tanpa *Transfer Learning* memprediksi seluruh data uji ke dalam satu kelas saja, yaitu kelas *Green*. Kondisi ini dikenal sebagai *mode collapse*, di mana model memilih satu kelas dominan untuk meminimalkan nilai *loss* tanpa benar-benar memahami karakteristik visual dari masing-masing kelas. Hal ini sangat kontras dengan model berbasis *Transfer Learning* yang mampu mendistribusikan prediksi secara proporsional ke seluruh kelas tingkat *roasting*.

Hasil eksperimen ini memberikan bukti empiris bahwa *Transfer Learning* merupakan komponen yang bersifat esensial dalam penelitian ini. Tanpa pemanfaatan fitur visual dasar seperti tepi, tekstur, dan bentuk yang telah dipelajari dari dataset berskala besar seperti *ImageNet*, arsitektur *deep learning* yang kompleks seperti *EfficientNet-B5* tidak dapat diterapkan secara efektif pada dataset biji kopi yang berukuran relatif kecil. Pendekatan *Transfer Learning* yang digunakan terbukti valid secara ilmiah dan mampu mengatasi keterbatasan data dalam tugas klasifikasi tingkat *roasting* biji kopi berbasis citra.

4.4. Implementasi Model dalam Aplikasi Web

Model klasifikasi tingkat *roasting* biji kopi yang telah dilatih diimplementasikan ke dalam aplikasi web berbasis *Streamlit* sebagai prototipe visualisasi sekaligus *proof of concept* untuk mendemonstrasikan kemampuan inferensi citra tunggal secara interaktif. Aplikasi ini menunjukkan pemanfaatan model *deep learning* sebagai alat bantu otomatis dalam penilaian tingkat *roasting* yang sebelumnya bergantung pada pengamatan manual dan bersifat subjektif.

Alur kerja aplikasi dimulai dari proses unggah citra oleh pengguna, dilanjutkan dengan pra-pemrosesan otomatis berupa *resizing* dan normalisasi, sebelum citra dimasukkan ke dalam model *EfficientNet-B5*. Hasil prediksi ditampilkan dalam bentuk kategori tingkat *roasting* (*Unroasted*, *Light*, *Medium*, atau *Dark*) beserta nilai *confidence score*. Implementasi dilakukan menggunakan *Streamlit* berbasis *Python* dengan model tersimpan dalam format *.keras*, serta didukung antarmuka yang mencakup fitur unggah citra, visualisasi input hingga modul *backend* untuk pra-pemrosesan.



Gambar 10. Antarmuka aplikasi klasifikasi:

- (a) tampilan awal halaman upload gambar;
(b) tampilan hasil prediksi setelah gambar di proses

Pengujian fungsional dilakukan untuk memastikan bahwa aplikasi dapat menampilkan hasil prediksi secara akurat dan sesuai dengan keluaran model. Tampilan antarmuka aplikasi saat dijalankan di lingkungan lokal ditunjukkan pada Gambar 10. Pada tampilan awal, pengguna disajikan widget untuk mengunggah citra biji kopi. Setelah citra diunggah, sistem secara otomatis memproses input dan menampilkan hasil klasifikasi di bawah citra asli. Contoh hasil pengujian menunjukkan bahwa model

berhasil memprediksi kategori *Medium* dengan tingkat kepercayaan sebesar 90.20%. Hasil ini membuktikan bahwa model *deep learning* yang dikembangkan diintegrasikan dengan baik pada aplikasi web dan berfungsi sesuai dengan tujuan penelitian sebagai klasifikasi tingkat *roasting* biji kopi berbasis citra.

4.5. Pembahasan

Penelitian ini bertujuan mengembangkan dan mengevaluasi model *deep learning* berbasis arsitektur *EfficientNet-B5* untuk klasifikasi tingkat *roasting* biji kopi. Hasil eksperimen menunjukkan performa sangat tinggi dengan akurasi pengujian 98,68% pada data uji, meskipun model dilatih menggunakan dataset terbatas sebanyak 1.600 citra. Temuan utama penelitian ini menegaskan peran *transfer learning*, di mana pelatihan tanpa bobot *pre-trained* gagal mencapai konvergensi, sedangkan inisialisasi dari *ImageNet* memungkinkan model mengekstraksi fitur visual secara efektif dan mencapai akurasi di atas 90%.

Dari sisi per kelas, model menunjukkan kinerja hampir sempurna pada kelas *Light* dan *Green* dengan nilai *Precision* dan *Recall* 0,99–1,00, sementara kesalahan kecil terjadi antara kelas *Medium* dan *Dark* akibat kemiripan karakteristik visual. Selain evaluasi metrik, model juga berhasil diimplementasikan dalam prototipe aplikasi web yang mampu melakukan pra-pemrosesan dan inferensi citra secara *real-time*. Implementasi ini membuktikan bahwa model unggul secara komputasional serta memiliki potensi praktis sebagai alat bantu objektif dalam penilaian tingkat *roasting* biji kopi.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa penerapan arsitektur *EfficientNet-B5* berbasis *transfer learning* mampu menghasilkan performa klasifikasi tingkat *roasting* biji kopi yang sangat baik pada empat kategori (*Unroasted*, *Light*, *Medium*, dan *Dark*), dengan akurasi pengujian 98,68% dan rata-rata *F1-Score* 0,98 yang mencerminkan kemampuan generalisasi tinggi. Eksperimen komparatif menegaskan peran *transfer learning* dalam mengatasi keterbatasan dataset, karena model tanpa bobot awal *ImageNet* gagal mencapai konvergensi. Model yang dikembangkan juga berhasil diintegrasikan ke dalam aplikasi web berbasis *Streamlit* untuk inferensi citra *real-time*. Pengembangan selanjutnya diarahkan pada perluasan dataset dengan variasi kondisi citra, peningkatan fitur sistem seperti *batch processing* dan penyimpanan riwayat prediksi, konversi ke format *TensorFlow Lite* untuk implementasi *mobile*, serta eksplorasi arsitektur atau pendekatan *ensemble* guna memperoleh performa yang lebih optimal.

DAFTAR PUSTAKA

- [1] Statista, "Coffee production in Indonesia from 2014 to 2024".
- [2] Statista, "Indonesia coffee market revenue forecast".

- [3] Roasts, "NCA - About Coffee".
- [4] M. Woschank and E. Rauch, "A Review of Further Directions for Artificial Intelligence , Machine Learning , and Deep Learning in Smart Logistics," *Sustainability*, vol. 12, p. 3760, 2020, doi: 10.3390/su12093760.
- [5] R. Primartha, "Belajar machine learning teori dan praktik," *Bandung: Informatika Bandung*, vol. 10, pp. 20–30, 2018.
- [6] S. N. Ria, M. Walid, and B. A. Umam, "Pengolahan Citra Digital Untuk Identifikasi Jenis Penyakit Kulit Menggunakan Metode Convolutional Neural Network (CNN) Digital," *Jurnal Energy (Jurnal Ilmiah Ilmu-ilmu Teknik)*, vol. 12, no. 2, pp. 62–67, 2022, doi: 10.51747/energy.v12i2.1118.
- [7] M. Z. Ersyad, K. N. Ramadhani, and A. Arifianto, "Pengenalan Bentuk Tangan dengan Convolutional Neural Network (CNN)," *e-Proceeding of Engineering*, vol. 7, no. 2, pp. 8212–8222, 2020.
- [8] M. Tan and Q. V Le, "EfficientNet : Rethinking Model Scaling for Convolutional Neural Networks," *International conference on machine learning, PMLR*, pp. 6105–6114, 2019.
- [9] V. Hoang and K. Jo, "Practical Analysis on Architecture of EfficientNet," *2021 14th International Conference on Human System Interaction (HSI)*, pp. 1–4, 2021.
- [10] S. J. Pan and Q. Yang, "A Survey on Transfer Learning," *IEEE Trans. Knowl. Data Eng.*, vol. 22, no. 10, pp. 1345–1359, 2009.
- [11] Anhar and R. A. Putra, "Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN)," *LKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 11, no. 2, pp. 466–478, 2023, doi: 10.26760/elkomika.v11i2.466.
- [12] Y. Omori and Y. Shima, "Image Augmentation for Eye Contact Detection Based on Combination of Pre-trained Alex-Net CNN and SVM," *J. Comput. (Taipei)*, vol. 15, no. 3, pp. 85–97, 2020.
- [13] A. Wijoyo, A. Y. Saputra, S. Ristanti, S. R. Sya'Ban, M. Amalia, and R. Febriansyah, "Pembelajaran Machine Learning," *OKTAL : Jurnal Ilmu Komputer dan Science*, vol. 3, no. 2, pp. 375–380, 2024.
- [14] J. W. G. Putra, "Pengenalan Konsep Pembelajaran Mesin dan Deep Learning," *Tokyo. Jepang*, 2019.
- [15] M. F. Naufal and S. F. Kusuma, "ANALISIS PERBANDINGAN ALGORITMA MACHINE LEARNING DAN DEEP LEARNING UNTUK KLASIFIKASI CITRA SISTEM ISYARAT BAHASA INDONESIA (SIBI)," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, vol. 10, no. 4, pp. 873–882, 2023, doi: 10.25126/jtiik.2023106828.
- [16] K. Azmi, S. Defit, and Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," *Jurnal Unitek*, vol. 16, no. 1, pp. 2580–2582, 2023.
- [17] V. Buhrmester, D. Münch, and M. Arens, "Analysis of Explainers of Black Box Deep Neural Networks for Computer Vision: A Survey," *Machine learning & knowledge extraction Perspective*, vol. 3, pp. 966–989, 2021, doi: 10.3390/make3040048.
- [18] A. Batool and Y. Byun, "Lightweight EfficientNetB3 Model based on Depthwise Separable Convolutions for Enhancing Classification of Leukemia White Blood Cell Images," *IEEE Access*, vol. 11, pp. 37203–37215, 2023, doi: 10.1109/ACCESS.2023.3266511.
- [19] P. Ramachandran, B. Zoph, and Q. V Le, "SEARCHING FOR ACTIVATION FUNCTIONS," pp. 1–13, 2017.
- [20] N. T. Adam, Z. A. Tyas, and T. Hardiani, "Deteksi Gestur Sistem Isyarat Bahasa Indonesia Menggunakan Metode Deep learning SSD MobileNet V2 FPNLite," *Sainteks*, vol. 21, no. 2, pp. 129–142, 2024, doi: 10.30595/sainteks.v21i2.24006.
- [21] J. Yosinski, J. Clune, Y. Bengio, and H. Lipson, "How transferable are features in deep neural networks?," *Adv. Neural Inf. Process. Syst.*, vol. 27, 2014.
- [22] T. Firmansyah, R. Kurniawan, and A. T. Hidayat, "Klasifikasi Tingkat Kematangan Roasting Biji Kopi Berbasis Deep Learning dengan Arsitektur MobileNet," *Journal of Information System Research (JOSH)*, vol. 6, no. 2, pp. 1432–1442, 2025, doi: 10.47065/josh.v6i2.6811.
- [23] I. C. Sari, M. K. Manurung, T. Rekayasa, P. Lunak, P. Wilmar, and B. Indonesia, "INTEGRASI MODEL DEEP LEARNING EFFICIENTNET-B0 UNTUK DETEKSI PENYAKIT DAUN TOMAT PADA APLIKASI SELULER BERBASIS FLUTTER," *Djtechno : Jurnal Teknologi Informasi*, vol. 5, no. 2, pp. 332–346, 2024, doi: 10.46576/djtechno.
- [24] I. Santoso, A. M. Manurung, and E. R. Subhiyakto, "Comparison of ResNet-50 , EfficientNet-B1 , and VGG-16 Algorithms for Cataract Eye Image Classification," *Journal of Applied Informatics and Computing (JAIC)*, vol. 9, no. 2, pp. 284–294, 2025.
- [25] S. Ontoum and T. Khemanantakul, "Coffee Roast Intelligence," *arXiv preprint*, 2022