



ADAPTASI SPESIFIK EFFICIENTNETB0 DENGAN LAPISAN KUSTOM UNTUK IDENTIFIKASI BUAH TROPIS

Dinul Akhiyar¹⁾, Hilda Herasmus²⁾ Nofriadiman³⁾

Teknologi Rekayasa Perangkat Lunak, Univesitas Putra Indonesia (Yptk) Padang

Universitas Ibnu Sina, Sekolah Tinggi Teknologi Industri Padang

Corresponding Author: ¹ dinul_akhiyar@upiyptk.ac.id

Article Info

Article history:

Received: 23 Juli 2025

Revised: 28 Juli 2025

Accepted: 10 August 2025

Published: 17 August 2025

Keywords:

Efficientnetb0, Adaptasi Model, Kalibrasi Bertahap, Identifikasi, Buah Tropis, CNN

ABSTRACT

Identifikasi buah tropis berbasis citra digital menghadapi tantangan multidimensi akibat keragaman morfologi intra-kelas (seperti variasi tingkat kematangan pada pisang) dan kesamaan visual antar-kelas (misalnya kemiripan geometris antara mangga dan nanas), diperparah oleh kondisi lingkungan lapangan yang tidak terkontrol seperti pencahayaan dinamis dan latar belakang kompleks. Untuk mengatasi masalah ini, penelitian ini mengusulkan strategi adaptasi spesifik domain pada arsitektur EfficientNetB0 melalui integrasi blok lapisan kustom yang terdiri dari *Dense Layer* 256-neuron dengan aktivasi *swish*, normalisasi lapisan (*Layer Normalization*), dan *Spatial Dropout* 0.3, serta mekanisme kalibrasi bertahap (*gradual unfreezing*) yang membuka lapisan konvolusional secara progresif. Dataset sebanyak 5.200 citra buah tropis Indonesia (pisang, mangga, nanas, durian, rambutan) diperkuat dengan teknik augmentasi dinamis berbasis *domain knowledge*, termasuk *color jitter* terarah dan *random erasing* untuk meniru variasi kondisi riil. Hasil eksperimen menunjukkan pencapaian akurasi validasi 88.7% dan F1-score rata-rata 0.87, yang mengungguli kinerja MobileNetV2 sebesar 6.4% dalam uji komparatif. Implementasi operasional dalam sistem FruitScan-ID membuktikan efektivitas metode ini dengan mengurangi kesalahan identifikasi manual hingga 40%, menawarkan solusi komputasi tepi (*edge-computing*) yang hemat sumber daya untuk otomatisasi industri pertanian tropis.



This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY SA 4.0)

1. INTRODUCTION

Identifikasi buah tropis berbasis komputer telah menjadi komponen kritis dalam transformasi digital industri pertanian Indonesia, khususnya dalam rantai pasok hortikultura. Proses identifikasi manual yang selama ini bergantung pada tenaga ahli menghadapi keterbatasan signifikan dalam konsistensi dan skalabilitas, terutama mengingat keragaman morfologi buah tropis yang unik. Tantangan utama terletak pada variasi intra-kelas yang ekstrem - seperti perubahan warna pisang dari hijau mentah hingga kuning matang - dan kemiripan visual antar kelas seperti kesamaan geometris antara mangga dan nanas. Kondisi lingkungan lapangan yang dinamis, termasuk pencahayaan tidak terkontrol dan latar belakang kompleks, semakin memperumit akurasi identifikasi

konvensional.

Sebagai solusi fundamental, pendekatan *deep learning* berbasis EfficientNetB0 menawarkan efisiensi melalui desain *compound scaling* yang mengoptimalkan akurasi dan konsumsi komputasi secara simultan. Arsitektur ini unggul dalam ekstraksi fitur multiskala menggunakan *inverted residual blocks* dengan ekspansi linier, memungkinkan pengenalan pola mulai dari tekstur mikro (seperti duri durian) hingga karakteristik makro (bentuk simetris nanas). Efisiensi komputasinya menjadi krusial mengingat implementasi di lapangan seringkali terkendala perangkat berdaya rendah, sehingga memungkinkan penerapan dalam infrastruktur komputasi tepi (*edge computing*) di kebun-kebun terpencil.

Inti penelitian ini terletak pada strategi adaptasi spesifik domain melalui tiga inovasi kunci: Pertama, penambahan blok lapisan kustom yang dirancang

husus untuk karakteristik buah tropis, menggabungkan *Dense Layer* 256-neuron dengan aktivasi *swish*, *Layer Normalization* sebagai stabilizer pembelajaran, dan *Spatial Dropout* untuk regularisasi spasial. Kedua, mekanisme kalibrasi bertahap (*gradual unfreezing*) yang membuka lapisan konvolusional secara progresif (6 lapisan/epoch) untuk mempertahankan pengetahuan umum dari ImageNet sambil mengakomodasi fitur spesifik buah. Ketiga, teknik augmentasi dinamis berbasis *domain knowledge* pertanian, termasuk *color jitter* terarah untuk simulasi variasi kematangan dan *random erasing* untuk ketahanan terhadap oklusi daun atau kotoran lapangan.

Strategi ini secara khusus diarahkan untuk mengatasi keterbatasan sumber daya melalui pendekatan komputasi cerdas: *Selective Backpropagation* hanya mengupdate gradien pada lapisan aktif selama fase kalibrasi, mengurangi beban memori hingga 40%. *Dynamic Batch Sizing* menyesuaikan ukuran batch berdasarkan kompleksitas sampel (batch kecil 16 untuk sampel sulit seperti pisang mentah-hijau, batch besar 32 untuk kelas mudah seperti durian). Implementasi *mixed-precision training* (FP16/FP32) lebih lanjut menekan kebutuhan GPU dari standar 8GB menjadi hanya 4GB, membuat solusi ini terjangkau untuk petani skala kecil dan menengah dengan infrastruktur terbatas.

Kunci keberhasilan terletak pada integrasi mendalam pengetahuan domain buah tropis: Sistem mengembangkan peta fitur *attention-driven* yang memberi bobot tinggi pada area kritis seperti pangkal tangkai pisang untuk identifikasi kematangan dan pola duri durian untuk membedakan varietas. Melalui *transfer learning silang* dari model identifikasi buah subtropis yang dimodifikasi dengan *tropical bias adjustment*, sistem mampu beradaptasi dengan karakteristik unik buah lokal. Kurikulum pembelajaran yang dirancang khusus memprioritaskan sampel ambigu (mis. mangga gedong vs. manalagi) pada fase akhir pelatihan, memastikan model menguasai kasus-kasus paling menantang dalam ekosistem pertanian Indonesia yang heterogen.


2. MATERIALS AND METHODS

2.1 Dataset

Dataset "Buah Tropis Indonesia" [5] yang digunakan dalam penelitian ini merupakan kumpulan citra digital spesifik konteks pertanian Indonesia, terdiri atas 5.200 citra RGB resolusi tinggi (1920×1080 piksel) yang mencakup lima kelas buah tropis unggulan: Pisang (*Musa spp.*), Mangga (*Mangifera indica*), Nanas (*Ananas comosus*), Durian (*Durio zibethinus*), dan Rambutan (*Nephelium lappaceum*). Data dikurasi secara ketat dengan memperhatikan variasi kritis dalam kondisi riil perkebunan Indonesia, termasuk

perbedaan tingkat kematangan (pisang mentah-hijau hingga matang-kuning), varietas lokal (mangga harum manis, gadung, manalagi), cacat permukaan, dan latarbelakang kompleks (kebun, pasar tradisional, proses pascapanen). Pembagian dataset mengikuti rasio 80:20 dengan 4.160 citra untuk pelatihan dan 1.040 citra untuk validasi, diambil secara stratifikasi untuk menjamin representasi proporsional setiap kelas dan meminimalkan bias evaluasi. Setiap citra dilengkapi metadata operasional seperti lokasi pengambilan (Sumatera, Jawa, Kalimantan), kondisi pencahayaan (natural/shadow/artificial), dan timestamp untuk mendukung analisis lingkungan.

2.2 Preprocessing dan Augmentasi Data
Proses pra-pemrosesan dan augmentasi data dilakukan secara sistematis untuk mengoptimalkan pembelajaran model sekaligus meningkatkan ketahanan terhadap variasi kondisi lapangan. Seluruh citra terlebih dahulu diubah dimensinya menjadi 224×224 piksel menggunakan interpolasi bikubik untuk memenuhi persyaratan input arsitektur EfficientNetB0, dengan tetap mempertahankan aspek rasio asli melalui teknik *reflective padding* guna menghindari distorsi geometris. Nilai intensitas piksel kemudian dinormalisasi ke rentang [0,1] melalui transformasi linear ($X' = X/255$) untuk mempercepat konvergensi selama pelatihan dan mengurangi dampak variasi pencahayaan. Tahap augmentasi mencakup tiga teknik strategis: (1) Rotasi acak hingga $\pm 45^\circ$ untuk mengakomodasi variasi sudut pengambilan gambar di lapangan; (2) Color jitter dengan modifikasi acak kecerahan ($\Delta=0.3$) dan kontras ($\Delta=0.3$) dalam ruang warna HSV guna mensimulasikan perubahan kondisi pencahayaan alami dari pagi hingga sore hari; serta (3) Random erasing yang secara acak menutupi 20% area citra dengan nilai piksel rata-rata untuk melatih ketahanan model terhadap oklusi parsial seperti tertutup daun, tangan petani, atau kerusakan sensor. Seluruh transformasi diaplikasikan secara *on-the-fly* selama pelatihan menggunakan *batch generator* untuk memaksimalkan keragaman data tanpa penambahan penyimpanan fisik data.



Gambar 1. Preprocessing dan Augmentasi Data

2.3 Arsitektur Model

Arsitektur model dalam penelitian ini mengadopsi pendekatan adaptasi spesifik domain melalui integrasi antara *backbone* EfficientNetB0 yang telah dipretraining dan blok klasifikasi kustom yang dirancang untuk karakteristik unik buah tropis. Model diawali dengan lapisan input $224 \times 224 \times 3$ yang sesuai dengan dimensi citra hasil preprocessing. *Backbone* EfficientNetB0 dimanfaatkan tanpa lapisan klasifikasi asli (`include_top=False`) untuk mengekstraksi fitur hierarkis, dengan bobot awal dari ImageNet yang dibekukan pada tahap awal pelatihan. Pada fitur map keluaran EfficientNetB0, diterapkan Global Average Pooling 2D untuk mengurangi dimensi spasial sambil mempertahankan informasi kanal


2.4 Strategi Pelatihan dan Fine-Tuning
 Penelitian ini menerapkan strategi kalibrasi bertahap (*gradual parameter calibration*) yang dirancang khusus untuk mengoptimalkan transfer pengetahuan dari dataset umum (ImageNet) ke domain spesifik buah tropis. Strategi ini diimplementasikan melalui dua fase pelatihan berurutan yang memadukan presisi dan efisiensi

Seluruh lapisan *backbone* EfficientNetB0 dibekukan untuk mempertahankan representasi fitur umum yang telah dipelajari dari ImageNet. Hanya blok klasifikasi kustom (Dense 256, BatchNorm, Dropout, dan lapisan output) yang dilatih menggunakan optimizer AdamW dengan *learning rate* relatif tinggi (0.001). Pemilihan AdamW (Adam dengan *weight decay*) diprioritaskan untuk mengontrol *exploding gradients* sekaligus mempercepat konvergensi lapisan

baru. Pada fase ini, augmentasi data diaplikasikan secara intensif (probabilitas 80%) untuk memaksa lapisan kustom beradaptasi cepat dengan variasi domain target. Strategi ini mengurangi *domain shift* sebesar 40% berdasarkan pengukuran *fréchet distance* antar distribusi fitur.

Sebanyak 30 lapisan teratas EfficientNetB0 secara selektif diaktifkan untuk pelatihan ulang dengan mekanisme unfreezing progresif:

- Mekanisme Gradual: 6 lapisan dibuka per epoch (lapisan 150-180 pada epoch 1, 144-150 pada epoch 2, dst.)
- Cyclic Learning Rate: Rentang dinamis $1e-5 \rightarrow 1e-4$ (policy triangular) untuk menghindari *local minima*
- Regularisasi Adaptif: *Weight decay* dinaikkan menjadi 0.01 pada lapisan akhir untuk mencegah overfitting



Gambar 2. Proses Kalibrasi bertahap

2.5 Evaluasi


Evaluasi kinerja model mengintegrasikan tiga kerangka analitik utama: (1) Pemantauan temporal akurasi dan loss per epoch menggunakan *Sparse Categorical Accuracy* dan *Cross-Entropy Loss* untuk mendeteksi anomali pelatihan seperti overfitting (gap training-validation > 0.2) atau stagnasi konvergensi ($\Delta \text{akurasi} < 0.5\%/\text{epoch}$), dengan mekanisme *early stopping* jika validasi loss tidak membaik selama 3 epoch berturut-turut; (2) Classification report granular yang menghitung presisi (ketepatan prediksi positif), recall (cakupan deteksi aktual), dan F1-score (harmonisasi presisi-recall) per kelas menggunakan *weighted averaging* pada subset validasi terstratifikasi, termasuk analisis mendalam terhadap kelas-kelas kritis seperti pisang mentah-matang yang memiliki variasi intra-kelas tinggi; serta (3) Confusion matrix diagnostik beranotasi warna dengan analisis pola kesalahan sistematis (mis. 12% misklasifikasi nanas-mangga) dan ketahanan pada kondisi sulit (oklusi 20% atau pencahayaan <50 lux).

Komplementasi dilakukan melalui analisis komparatif arsitektur (EfficientNetB0: akurasi 88.7%, F1-score 0.87, RAM 142MB vs MobileNetV2: 82.3%, 0.79, 94MB), pengukuran KPI operasional seperti throughput (68 citra/detik di GPU), presisi kelas bernilai tinggi (durian premium >95%), dan *false positive cost* ekonomi; serta validasi silang domain pada dataset independen Buah Tropis Malaysia (2.100 citra) yang menunjukkan ketahanan kinerja (akurasi

84.3%, penurunan F1-score hanya 0.04 pada rambutan). Pendekatan multimetrik ini menghasilkan *diagnosis preskriptif* untuk optimisasi iteratif: identifikasi kebutuhan *attention module* (+17% akurasi pisang mentah), *color calibration* (-22% kesalahan nanas-mangga), dan *edge-computation tuning* (percepatan inferensi 3× di Raspberry Pi 4 dengan latency 23ms/citra).

3. RESULTS AND DISCUSSION

3.1 Tren Akurasi dan Loss



Gambar 3. Grafik akurasi dan loss

Gambar 3 memperlihatkan grafik akurasi dan loss. Grafik akurasi dan loss (Gambar 1) menunjukkan konvergensi optimal dengan akurasi akhir 88.7% dan loss validasi 0.28 setelah 15 epoch, di mana Fase Inisialisasi (epoch 1-5) mencatat kenaikan akurasi stabil dari 62.4% ke 79.1% dengan gap training-validation <0.05, sedangkan Fase Kalibrasi (epoch 6-15) memicu lonjakan akurasi 9.6% dalam 3 epoch pertama akibat unfreezing blok 7 EfficientNetB0 yang sensitif terhadap pola makro buah, meskipun sempat mengalami kenaikan loss sementara +0.12 di epoch 10 saat unfreezing blok 5 (filter tekstur mikro) yang berhasil diatasi oleh penyesuaian *learning rate cyclic* (1e-5→8e-5). Efektivitas strategi terkonfirmasi melalui stabilitas tinggi (fluktuasi akurasi validasi <±0.8% di 5 epoch akhir), kesalahan kalibrasi minimal (gap loss akhir 0.09), dan efisiensi waktu (85% akurasi tercapai sebelum epoch 10), sementara analisis granular mengungkap variasi pembelajaran antar kelas: Durian mencapai 90% akurasi di epoch 7 berkat ekstraksi fitur duri optimal, Pisang mengalami stagnasi hingga epoch 11 akibat variasi kematangan, dan insiden kritis Nanas-Mangga di epoch 9 (kenaikan loss 23%) yang berhasil diredam mekanisme SWA hingga misklasifikasi turun dari 15% ke 8%, dengan performa akhir terekapitulasi dalam akurasi kelas: Durian (92.1%), Rambutan (90.3%), Pisang (85.4%), Mangga (88.7%), dan Nanas (83.2%).


3.2 Laporan Klasifikasi

Kelas	Precisio	Recal	F1-Score	Support	Deskripsi Performa
Durian	0.92	0.91	0.92	205	Ekstraksi tekstur duri optimal
Rambutan	0.89	0.90	0.90	217	Manfaat augmentasi <i>random erasing</i>
Mangga	0.87	0.89	0.88	212	F1-score tertinggi antar kelas
Pisang	0.91	0.85	0.88	208	Disparitas precision-recall tertinggi
Nanas	0.84	0.83	0.84	198	Misklasifikasi 12% → Mangga
Makro Avg	0.886	0.876	0.87	-	-
Weighted Avg	0.883	0.874	0.87	1040	-

Tabel 1. Nilai precision, recall, dan f1-score tiap kelas

Tabel 1 menunjukkan performa model yang diukur melalui precision, recall, dan F1-score pada lima kelas buah tropis, mengungkap disparitas signifikan yang terkait karakteristik visual: Durian mencatat F1-score tertinggi (0.92) berkat keunikan tekstur duri yang konsisten diekstraksi lapisan awal EfficientNetB0, diikuti Rambutan (F1=0.90) yang mendapat manfaat dari augmentasi *random erasing* untuk ketahanan terhadap variasi kerapatan rambut; sementara Pisang menunjukkan disparitas precision-recall tertinggi (presisi 0.91 vs recall 0.85) akibat kesalahan identifikasi pisang mentah-hijau sebagai *false positive* kelas mangga, dan Nanas menjadi kelas tersulit (F1=0.84) karena misklasifikasi 12% sebagai mangga ketika buah terpotong parsial dalam citra. Secara agregat, model mencapai presisi makro 0.886 dan recall makro 0.876, dengan F1-score rata-rata 0.87 yang didominasi performa kuat kelas durian-rambutan, sementara tantangan utama terletak pada manajemen *false negative* pisang (15% sampel mentah tak terdeteksi) dan *false positive* nanas-mangga (9% kesalahan sistematis). Perbedaan performa ini secara kuantitatif terpaut 8.7% antara kelas terbaik (durian) dan tersulit (nanas), merefleksikan kompleksitas geometris nanas yang multi-skalar dan variasi intra-kelas pisang yang ekstrem..

3.3 Confusion Matrix



Gambar 4. Confusion matrix model terbaik.

Confusion matrix (Gambar 4) mengungkap pola kesalahan sistematis dengan akurasi diagonal dominan (>90% untuk Durian dan Rambutan) tetapi misklasifikasi kritis pada tiga cluster: (1) 12% Nanas terklasifikasi sebagai Mangga terutama saat buah terpotong parsial atau berlatarbelakang kompleks, akibat kemiripan geometri bulat dan pola tekstur permukaan; (2) 9% Pisang mentah-hijau terkategori Mangga karena kesamaan distribusi warna HSV (Hue: 70-85°) dalam kondisi cahaya rendah; dan (3) 7% Rambutan matang-terlalu dideteksi sebagai Durian ketika rambut buah rontok mengekspos tekstur kulit kecoklatan. Secara kuantitatif, 28% total error berpusat pada interaksi Nanas-Pisang-Mangga yang merefleksikan tantangan domain spesifik: kompleksitas geometri multi-skalar (Nanas), variasi intra-kelas ekstrem (Pisang mentah-matang), dan overlap ruang warna (Mangga-Nanas). Solusi preskriptif teridentifikasi: penambahan augmentasi orientasi 360° untuk kasus buah terpotong, normalisasi berbasis maturitas untuk Pisang, dan preprocessing HSV-weighted guna memperkuat diskriminator warna.

4. CONCLUSION

Penelitian ini berhasil membuktikan efektivitas strategi adaptasi spesifik domain pada EfficientNetB0 yang dikombinasikan dengan blok lapisan kustom (Dense 256-Swish + LayerNorm + Dropout 0.4) dan kalibrasi bertahap (*gradual unfreezing* 30 lapisan dengan *cyclic LR*), menghasilkan akurasi identifikasi buah tropis 88.7% - peningkatan signifikan 6.4% dibanding MobileNetV2 dan 3.6% dari *full fine-tuning* konvensional, dengan efisiensi komputasi tercermin dari waktu pelatihan 48 menit dan *inference latency* 23

ms/citra di Raspberry Pi 4. Secara operasional, implementasi dalam sistem FruitScan-ID telah mengurangi kesalahan klasifikasi manual hingga 40% khususnya pada rantai pasok durian dan rambutan premium, meskipun tantangan tersisa pada manajemen variasi intra-kelas pisang (akurasi mentah-matang 78.3%) dan diskriminasi geometri nanas-mangga (12% misklasifikasi). Untuk adopsi industri, direkomendasikan: (1) Integrasi *attention module* berbasis CBAM untuk meningkatkan fusi fitur multi-skala; (2) Pengembangan *maturity-index normalization layer* khusus kelas pisang; dan (3) Ekspansi dataset dengan citra hyperspectral untuk menangkap variasi biokimia kematangan buah, sementara riset lanjutan diarahkan pada *cross-geography validation* menggunakan dataset buah tropis Asia Tenggara dan eksplorasi arsitektur Vision Transformer dengan mekanisme *adaptive token sampling*.

REFERENCES

1. A. Wicaksono et al., "Automated Fruit Quality Inspection in Indonesia," *J. Agric. Eng.*, vol. 12, no. 3, pp. 45–58, 2023. *Penelitian dasar untuk konteks otomasi pertanian Indonesia.*
2. M. Tan dan Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," dalam *Proc. 36th Int. Conf. Mach. Learn.*, 2019, pp. 6105–6114. *Dasar arsitektur model utama.*
3. S. Wibowo et al., "Computer Vision for Tropical Agriculture," *IEEE Trans. Agri-Informatics*, vol. 5, no. 2, pp. 112–125, 2023. *Studi spesifik tantangan buah tropis.*
4. T. Sutrisno dan D. A. Iswanto, "Hybrid Augmentation Strategy for Robust Fruit Classification," *Comput. Electron. Agric.*, vol. 208, 2023, Art. no. 107782. *Strategi augmentasi domain-spesifik.*
5. R. Utami et al., "Gradual Unfreezing for Domain-Specific Transfer Learning," *J. Mach. Learn. Res.*, vol. 24, no. 128, pp. 1–32, 2023. *Landasan teori kalibrasi bertahap.*
6. A. R. Wijaya, "Edge-Computing Optimization for Fruit Grading Systems," *IEEE Embedded Syst. Lett.*, vol. 15, no. 2, pp. 65–68, 2023. *Optimisasi implementasi edge computing.*
7. Kementan RI, *Statistik Hortikultura 2023*. Jakarta: Pusat Data Pertanian, 2023. *Data resmi konteks pertanian Indonesia.*
8. *Buah Tropis Indonesia Dataset*, versi 1.1. Zenodo, 2023. [Daring]. Tersedia: <https://doi.org/10.5281/zenodo.7890123> *Dataset utama penelitian.*
9. B. Sutrisno, "Domain Adaptation Techniques for Agricultural AI," *J. Agri. Tech.*, vol. 12, no. 3, pp. 89–104, 2024. *Metodologi adaptasi domain.*
10. L. Chen et al., "Attention Mechanisms for Fine-Grained Visual Classification," *Pattern Recognit.*, vol. 115, 2024, Art. no. 107901. *Rekomendasi implementasi attention module.*
11. P. Sharma et al., "Hyperspectral Imaging for Fruit Maturity Assessment," *Biosyst. Eng.*, vol. 212, pp. 203–215, 2024. *Dasar ekspansi data hyperspectral.*
12. D. Liu dan W. Deng, "Vision Transformers in Agricultural Robotics," *Robotics Auton. Syst.*, vol. 163, 2024, Art. no. 104385. *Studi komparatif Vision Transformer.*
13. TensorFlow Documentation, *Custom Layers and Models*. Google, 2024. [Daring]. Tersedia:

https://www.tensorflow.org/guide/keras/custom_layers_and_models

Implementasi teknis lapisan kustom.

14. **A. Krizhevsky et al.**, "ImageNet Classification with Deep CNNs," *Commun. ACM*, vol. 60, no. 6, pp. 84–90, 2017.
Landasan transfer learning.
15. **F. Chollet**, *Deep Learning with Python*, 2nd ed. Shelter Island, NY: Manning Publications, 2021.
Buku acuan arsitektur dasar.