

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil perancangan, implementasi, serta serangkaian eksperimen yang telah dilakukan terhadap sistem Klasifikasi *Cascade* Jenis dan Tingkat Sangrai Biji Kopi Berbasis Citra Menggunakan EfficientNet-B0, dapat ditarik beberapa kesimpulan utama sebagai berikut:

1. Perbandingan Akurasi Model *Cascade* dan Model *Flat*: Pendekatan *Cascade Classification* terbukti secara konsisten mengungguli *Flat Classification* pada kedua variasi dataset yang diuji. Pada pengujian menggunakan dataset tanpa segmentasi, sistem *Cascade* berhasil mencapai akurasi global tertinggi sebesar 94%, mengungguli model *Flat Classification* yang memperoleh akurasi sebesar 92%. Sementara itu, pada pengujian menggunakan dataset tersegmentasi, sistem *Cascade* mencapai akurasi global sebesar 88%, yang juga lebih tinggi dibandingkan model *Flat Classification* dengan akurasi sebesar 87%.
2. Analisis Penurunan Akurasi pada Dataset Tersegmentasi: Terjadi penurunan akurasi global sebesar 6% pada model *Cascade* (dari 94% menjadi 88%) dan 5% pada model *Flat* (dari 92% menjadi 87%) saat menggunakan dataset tersegmentasi dibandingkan dataset tanpa segmentasi. Penurunan ini disebabkan oleh beberapa faktor teknis berikut:
 - Kehilangan Konteks Spasial dan Kontras Latar Belakang: Citra tanpa segmentasi menyediakan informasi kontras alami antara biji kopi dan latar belakang (*background*) yang membantu arsitektur EfficientNet-B0 dalam mengenali batas fisik serta kedalaman gradasi warna.
 - Artefak Perbatasan (Boundary Artifacts): Pemisahan objek biji menggunakan teknik segmentasi (*thresholding*) berpotensi

menghilangkan atau merusak sebagian piksel pada area tepi/kontur biji. Hal ini mengurangi detail morfologi halus yang sangat krusial untuk membedakan varietas dengan kemiripan bentuk tinggi (seperti Ekselsa dan Liberika).

- Distorsi Skala Tekstur (Rescaling Effect): Pengisolasian Region of Interest (ROI) biji tunggal yang dilanjutkan dengan pemotongan (*cropping*) dan *resizing* ke dimensi 224×224 piksel mengakibatkan peregangan/perubahan skala tekstur mikro pada permukaan biji. Hal ini memicu ambiguitas ekstraksi fitur warna dan tekstur pada tahap klasifikasi tingkat sangrai.
3. Efektivitas Dekomposisi Tugas dalam Mengatasi Ambiguitas Visual (*Inter-class Similarity*): Penerapan metode inferensi bertingkat (*cascade*) berhasil memecah kompleksitas klasifikasi 16 kombinasi kelas menjadi dua tahap sekuensial, yaitu pengenalan jenis varietas (Arabika, Robusta, Liberika, Ekselsa) pada tahap pertama dan diikuti penentuan tingkat sangrai (*Green, Light, Medium, Dark*) pada tahap kedua. Strategi ini terbukti lebih efektif dalam menekan tumpang-tindih fitur visual (*inter-class similarity*) dibandingkan model *Flat Classification* yang dipaksa memprediksi seluruh 16 kombinasi kelas secara bersamaan dalam satu kali eksekusi.
 4. Kontribusi Prapemrosesan Citra dan Arsitektur EfficientNet-B0: Kombinasi prapemrosesan citra—yang meliputi reduksi *noise* dengan *Gaussian Blur*, penyesuaian kontras tekstur permukaan dengan CLAHE, serta penyeragaman dimensi ke 224×224 piksel—memberikan masukan data yang bersih dan konsisten bagi jaringan konvolusi. Arsitektur EfficientNet-B0 terbukti sangat efisien dengan parameter yang ringkas (sekitar 5,3 juta parameter) namun tetap akurat dalam mengekstraksi fitur morfologi dan gradasi warna biji kopi.
 5. Analisis Performa Per-Varietas dan Perambatan Kesalahan (*Error Propagation*): Model *Cascade* menunjukkan performa yang sangat tinggi pada varietas Arabika dan Robusta, di mana beberapa kelas (seperti Arabika_Green,

Arabika_Light, dan Robusta_Medium) mencapai F1-score mutlak sebesar 1,00. Tantangan utama klasifikasi terletak pada varietas Ekselsa dan Liberika akibat kemiripan morfologi fisik serta dominasi warna gelap pada tingkat sangrai *Dark*. Pada model *Cascade*, ketidaktepatan prediksi jenis pada tahap pertama menyebabkan terjadinya *error propagation* (perambatan kesalahan) ke tahap kedua (seperti beberapa sampel Ekselsa_Dark yang salah terarah ke cluster Liberika_Dark). Meskipun demikian, secara keseluruhan model *Cascade* tetap menghasilkan ketahanan dan stabilitas prediktif global yang lebih unggul dibanding model *Flat*.

5.2 Saran

Guna mengoptimalkan kualitas sistem serta membuka peluang pengembangan penelitian lebih lanjut di masa mendatang, beberapa saran yang dapat diajukan adalah:

1. Perluasan Dataset: Perlu dilakukan penambahan volume sampel citra secara masif, khususnya untuk varietas eksotis seperti Liberika dan Ekselsa. Penambahan variasi data visual dari berbagai variasi bentuk fisik akan membantu model dalam memperdalam pemisahan fitur morfologi unik antar-varietas, sehingga dapat mereduksi tingkat misklasifikasi lintas varietas (*cross-variety*) pada tingkat sangrai yang sama.
2. Eksperimen Strategi Pelatihan dan Hyperparameter: Disarankan untuk mengeksplorasi variasi nilai yang lebih dinamis atau memodifikasi laju pembelajaran bertingkat (*discriminative learning rates*) pada sub-model tahap kedua. Hal ini diperlukan untuk mempertajam sensitivitas model dalam membedakan transisi warna yang tipis antara profil *light*, *medium*, dan *dark*.
3. Penerapan pada Perangkat Bergerak (*Mobile Deployment*): Mengingat arsitektur EfficientNet-B0 memiliki beban komputasi yang rendah dan ukuran model yang ringan, sistem ini berpotensi untuk diintegrasikan ke dalam aplikasi berbasis Android atau iOS. Penerapan pada smartphone akan mempermudah demokratisasi teknologi ini agar dapat digunakan secara praktis oleh pemilik

roastery lokal, barista, maupun petani kopi di lapangan untuk keperluan kontrol kualitas (*quality control*) mandiri.

4. Pengujian pada Kondisi Pencahayaan Dinamis: Penelitian selanjutnya dapat mencoba mengimplementasikan teknik prapemrosesan citra yang bersifat *illumination-invariant* (kebal terhadap fluktuasi cahaya). Hal ini penting untuk menjamin konsistensi akurasi model ketika diuji menggunakan kamera perangkat seluler di lingkungan luar laboratorium yang tidak memiliki bantuan pencahayaan lampu LED yang stabil.