

BAB 5. KESIMPULAN

5.1. Kesimpulan

Berdasarkan hasil penelitian dan serangkaian percobaan klasifikasi motif Ulos menggunakan model ResNet50 dan VGG19 dengan berbagai variasi *preprocessing* dan modifikasi, diperoleh beberapa kesimpulan sebagai berikut:

1. Model VGG19 menunjukkan performa klasifikasi yang lebih stabil dan unggul dibandingkan ResNet50 di hampir semua percobaan. Hal ini ditunjukkan oleh nilai akurasi, khususnya pada percobaan kelima yang menghasilkan akurasi hingga 89.58%, jauh di atas ResNet50 (61.46%). VGG19 juga lebih mampu menjaga keseimbangan antar kelas berdasarkan nilai *macro average*, yang menunjukkan kemampuannya dalam menggeneralisasi pola ulos secara merata.
2. *Preprocessing* citra seperti *sharpening* dan *denoising* memiliki dampak signifikan terhadap performa model, namun efektivitasnya sangat tergantung pada konsistensi penerapannya. Percobaan kedua dan keempat menunjukkan bahwa ketika *preprocessing* hanya diterapkan pada subset tertentu (hanya data latih), terjadi penurunan drastis pada akurasi dan metrik evaluasi lainnya. Ini membuktikan bahwa ketidaksesuaian distribusi visual antar subset (*train*, validasi, dan uji) menyebabkan model *overfitting* atau gagal beradaptasi dengan data baru. Namun, untuk dataset motif ulos, penggunaan filter terbukti tidak membantu dan bahkan dapat dihindari.
3. Modifikasi arsitektur model, khususnya penggantian *GlobalAveragePooling2D* menjadi *GlobalMaxPooling2D*, memberikan pengaruh positif yang signifikan terhadap kinerja model. Percobaan kelima menunjukkan bahwa perubahan struktural ini lebih efektif dalam meningkatkan akurasi dan kemampuan generalisasi model dibandingkan sekadar manipulasi data input. *GlobalMaxPooling* membantu model fokus pada fitur dominan dari citra ulos, yang sesuai untuk membedakan motif dengan detail visual yang mirip.
4. Dari sisi kompleksitas model, ResNet50 memiliki jumlah parameter *trainable* dan ukuran *file* model yang lebih besar dibandingkan VGG19,

namun tidak diikuti dengan hasil klasifikasi yang lebih baik. VGG19, meskipun memiliki parameter *trainable* yang lebih kecil, justru menghasilkan performa yang lebih konsisten. Hal ini menunjukkan bahwa kecocokan arsitektur terhadap karakteristik dataset lebih penting dibandingkan sekadar jumlah parameter atau kedalaman model.

5. Dari sisi efisiensi komputasi, ResNet50 umumnya membutuhkan waktu pelatihan yang sedikit lebih singkat dibandingkan VGG19. Pada percobaan pertama hingga keempat, waktu pelatihan ResNet50 lebih cepat antara ± 1 hingga 4 menit. Namun, pada percobaan kelima, waktu pelatihan ResNet50 justru lebih lama dibanding VGG19 karena pengaruh dari perubahan struktur *pooling*. Hal ini menunjukkan bahwa efisiensi komputasi tidak hanya dipengaruhi oleh jenis arsitektur, tetapi juga oleh konfigurasi internal seperti jenis *pooling* yang digunakan.

Berdasarkan rangkaian evaluasi yang telah dilakukan, VGG19 menghasilkan performa terbaik karena arsitekturnya yang dalam namun sederhana memungkinkan model menangkap detail halus pada motif ulos secara bertahap dan konsisten. Metode konvolusi bertingkat tanpa *shortcut connection* seperti pada ResNet50 membuat VGG19 lebih stabil dalam proses pembelajaran, terutama pada dataset berukuran sedang dengan pola visual kompleks seperti ulos. Selain itu, penerapan *GlobalMaxPooling2D* pada percobaan kelima semakin menguatkan kemampuan model dalam menonjolkan fitur paling relevan, sehingga meningkatkan akurasi secara signifikan. Kombinasi antara struktur arsitektur yang efisien dan kemampuan adaptasi terhadap modifikasi membuat VGG19 unggul dalam mengenali variasi motif ulos dengan lebih akurat dibandingkan ResNet50.

5.2. Saran

Penulis menyadari bahwa penelitian ini masih memiliki beberapa keterbatasan, baik dari segi jumlah data, jenis arsitektur yang diuji, maupun variasi eksperimen yang dilakukan. Oleh karena itu, untuk pengembangan penelitian di masa mendatang, berikut beberapa hal yang dapat dipertimbangkan:

1. Mengeksplorasi arsitektur model lain yang lebih ringan namun tetap efektif, seperti MobileNet, EfficientNet, atau DenseNet. Arsitektur-arsitektur ini

berpotensi memberikan efisiensi komputasi yang lebih baik, terutama jika penelitian ingin diarahkan ke implementasi di perangkat dengan keterbatasan sumber daya.

2. Mencoba melakukan *fine-tuning* pada layer tertentu dari model *pretrained*, agar model dapat lebih menyesuaikan diri dengan karakteristik khusus motif ulos, dan tidak hanya bergantung pada pola umum dari dataset pelatihan awal seperti ImageNet.
3. Menambah jumlah *epoch* saat pelatihan model, terutama pada eksperimen yang belum menunjukkan hasil optimal. Hal ini bisa memberikan waktu belajar yang lebih panjang bagi model untuk mengenali pola secara lebih optimal.
4. Menerapkan teknik augmentasi data yang lebih bervariasi untuk memperbanyak variasi citra pelatihan. Augmentasi ini dapat membantu model menjadi lebih optimal dalam mengenali motif ulos dengan berbagai kondisi visual.
5. Mengembangkan aplikasi berbasis model klasifikasi, misalnya dalam bentuk sistem identifikasi ulos otomatis pada perangkat seluler atau web. Aplikasi ini dapat dimanfaatkan oleh masyarakat umum, pelajar, maupun pelaku budaya untuk mengenali jenis-jenis ulos secara cepat dan akurat, serta menjadi sarana edukasi digital tentang warisan budaya Batak.

Penulis berharap saran-saran ini dapat menjadi bahan pertimbangan bagi peneliti selanjutnya dalam mengembangkan sistem klasifikasi citra yang lebih akurat, efisien, dan berdampak langsung bagi pelestarian budaya.