

BAB V

PENUTUP

5.1 Kesimpulan

Penelitian ini telah berhasil mengidentifikasi keefektifan dan membandingkan kinerja lima model arsitektur *Transfer Learning* (*VGG16*, *VGG19*, *MobileNetV3*, *Inception-V3*, dan *EfficientNetV2*) dalam tugas klasifikasi motif kain ulos tradisional. Berdasarkan hasil evaluasi menggunakan berbagai metrik, seperti akurasi, presisi, *recall*, dan *F1-score*, penelitian ini menunjukkan bahwa model *Inception-V3* memiliki kinerja yang paling optimal:

1. Hasil analisis menunjukkan bahwa *InceptionV3* adalah model arsitektur *transfer learning* yang paling efektif untuk klasifikasi motif kain ulos tradisional. *InceptionV3* menunjukkan waktu pelatihan yang efisien dengan rata-rata waktu per *epoch* sekitar 13-14 detik dan total waktu pelatihan kurang dari 12 menit. Model ini memiliki kompleksitas tinggi dengan 22.07 juta parameter dan memori sebesar 84.17 MB, namun memberikan akurasi validasi tertinggi rata-rata 98,13% pada berbagai konfigurasi *learning rate* dan stabilitas performa yang sangat baik dalam klasifikasi antar kelas. Dalam evaluasi *K-fold cross validation*, *InceptionV3* mencatatkan akurasi rata-rata tertinggi dan *loss* terendah, menandakan kemampuan generalisasi yang kuat. Dalam evaluasi *K-fold cross validation*, *InceptionV3* mencatatkan akurasi rata-rata tertinggi dan *loss* terendah, menandakan kemampuan generalisasi yang kuat. Sebaliknya, *VGG16* dan *VGG19* menunjukkan performa yang sangat baik pada *learning rate* (1×10^{-3}), dengan akurasi validasi mendekati 99%. Namun, pada *learning rate* (1×10^{-4}), kedua model ini mengalami penurunan akurasi yang signifikan dan menunjukkan kecenderungan *overfitting* pada *learning rate* yang lebih tinggi. *VGG16* memiliki 14.78 juta parameter dan memori 56.39 MB, sedangkan *VGG19* memiliki 20.09 juta parameter dan memori 76.64

MB. Meskipun membutuhkan waktu pelatihan yang lebih lama dengan waktu rata-rata per *epoch* sekitar 23-25 detik dan total waktu pelatihan sekitar 20 menit, kedua model ini tetap menjadi pilihan yang solid untuk tugas ini pada *learning rate* yang lebih tinggi. *MobileNetV3Large* dan *EfficientNetV2B1* menunjukkan performa yang kurang memuaskan. *MobileNetV3Large*, dengan 3.12 juta parameter dan memori 11.90 MB, mencapai akurasi validasi terendah di antara semua model pada *learning rate* (1×10^{-3}) dan (1×10^{-4}). *EfficientNetV2B1*, yang memiliki 7.10 juta parameter dan memerlukan 27.07 MB memori, menunjukkan performa yang tidak konsisten dan cenderung lebih buruk dalam seluruh metrik evaluasi. Hasil ini menunjukkan bahwa meskipun kedua model ini lebih efisien dalam hal memori dan parameter, mereka kurang efektif dalam tugas klasifikasi motif kain ulos tanpa penyesuaian lebih lanjut.

2. Berdasarkan metrik evaluasi, *InceptionV3* menunjukkan kinerja terbaik dengan akurasi rata-rata tertinggi dan *loss* terendah pada kedua *learning rate* dan *K-fold cross validation*, serta stabilitas performa yang sangat baik. Model ini memiliki akurasi validasi rata-rata mencapai 98,13% dan *loss* rata-rata terendah sebesar 5,67%, menunjukkan bahwa ia mampu mengklasifikasikan motif kain ulos tradisional dengan sangat akurat dan konsisten.
3. Hasil uji ANOVA dua arah menunjukkan bahwa terdapat perbedaan yang signifikan dalam kinerja model-model yang diuji, sehingga hipotesis nol untuk faktor Model ditolak. Model seperti VGG16, VGG19, dan *InceptionV3* menunjukkan kinerja yang lebih baik dalam klasifikasi motif kain ulos tradisional dibandingkan model lainnya. Selain itu, metode pelatihan yang diterapkan juga berpengaruh signifikan terhadap kinerja, yang menyebabkan penolakan hipotesis nol untuk faktor Metode. Terakhir, uji ANOVA juga mengungkapkan adanya interaksi signifikan antara jenis model dan metode pelatihan, yang menunjukkan bahwa efektivitas model bergantung pada konfigurasi pelatihan yang digunakan. Temuan ini menegaskan bahwa penyesuaian spesifik diperlukan untuk memperoleh performa terbaik dari setiap model.

5.2 Saran

Berikut ini adalah beberapa saran dari penulis untuk penelitian selanjutnya, yaitu:

1. Eksplorasi penyesuaian hyperparameter lebih lanjut, termasuk *learning rate* adaptif, *optimizers* alternatif, dan teknik regularisasi tambahan untuk mengurangi *underfitting* dan *overfitting* pada model-model tertentu.
2. Uji kinerja model pada gambar dengan variasi kondisi pencahayaan dan resolusi yang berbeda untuk meningkatkan *robustness* dalam situasi nyata.
3. Kembangkan atau sesuaikan model untuk mencapai efisiensi memori yang lebih baik sambil mempertahankan akurasi tinggi, memungkinkan implementasi pada perangkat dengan sumber daya terbatas.
4. Investigasi lebih lanjut tentang pengaruh teknik pelatihan lain, seperti *transfer learning* dengan *fine-tuning* ekstensif atau teknik *ensemble*, untuk meningkatkan kinerja keseluruhan model.
5. Implementasikan model terbaik dalam aplikasi nyata, seperti sistem identifikasi otomatis motif ulos di industri tekstil atau museum.