

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan enam belas hasil pengujian pada delapan kelas rimpang dengan menggunakan arsitektur *MobileNetV3-Large* dan *EfficientNetB2*, baik pada data citra asli maupun citra yang dikombinasikan dengan fitur *Local Binary Pattern* (LBP), serta menggunakan variasi *learning rate* sebesar 0.1, 0.01, 0.001 dan 0.0001 dengan pembagian data 80% latih, 10% validasi, dan 10% uji, maka diperoleh kesimpulan sebagai berikut:

1. Hasil perbandingan kinerja *MobileNetV3-Large* dan *EfficientNetB2* pada kondisi tanpa dan dengan penambahan fitur LBP, hasil pengujian menunjukkan bahwa penambahan LBP mampu meningkatkan performa kedua arsitektur secara konsisten. Pada *MobileNetV3-Large* tanpa LBP, konfigurasi terbaik diperoleh pada Hasil Pengujian 4 (LR 0.0001) dengan *accuracy* 0.9750, *precision* 0.9765, *recall* 0.9750, dan *f1-score* 0.9751. Setelah ditambah LBP, performa terbaik beralih pada Hasil Pengujian 8 (LR 0.0001) dengan *accuracy* 0.9800, *precision* 0.9815, *recall* 0.9800, dan *f1-score* 0.9799. Pola serupa terlihat pada *EfficientNetB2*: pada citra asli, konfigurasi terbaik terdapat pada Hasil Pengujian 12 (LR 0.0001) dengan *accuracy* 0.9800, *precision* 0.9806, *recall* 0.9800, dan *f1-score* 0.9799, kemudian meningkat lagi ketika digabung dengan LBP pada Hasil Pengujian 16 dengan *accuracy* 0.9850, *precision* 0.9859, *recall* 0.9850, dan *f1-score* 0.9850. Dengan demikian, perbandingan kinerja menunjukkan bahwa kombinasi citra asli dan LBP memberikan hasil yang lebih baik pada kedua arsitektur dibandingkan hanya menggunakan citra asli.
2. Variasi *learning rate* berpengaruh signifikan terhadap kinerja kedua arsitektur, terlihat dari perubahan nilai *accuracy*, *precision*, *recall*, dan *f1-score* pada setiap hasil pengujian. *Learning rate* yang terlalu besar (0.1 dan 0.01) menyebabkan model gagal belajar secara efektif, misalnya pada *MobileNetV3-Large* citra asli: Hasil Pengujian 1 memberikan *accuracy*

0.1300. *precision* 0.1407, *recall* 0.1300. dan *f1-score* 0.0375, sedangkan Hasil Pengujian 2 hanya mencapai *accuracy* 0.1950. *precision* 0.3967, *recall* 0.3950. dan *f1-score* 0.3508; kondisi serupa tampak pada *EfficientNetB2* citra asli, di mana Hasil Pengujian 9 menghasilkan *accuracy* 0.1250. *precision* 0.0156, *recall* 0.1250. dan *f1-score* 0.0278, serta Hasil Pengujian 10 dengan *accuracy* 0.5800. *precision* 0.8434, *recall* 0.5800. dan *f1-score* 0.6045. Sebaliknya, ketika *learning rate* diturunkan menjadi 0.001 dan 0.0001, performa model meningkat tajam: *MobileNetV3-Large* dengan LBP pada Hasil Pengujian 8 mencapai *accuracy* 0.9800. *precision* 0.9815, *recall* 0.9800. dan *f1-score* 0.9799, sementara *EfficientNetB2* menunjukkan kestabilan tinggi pada *learning rate* kecil, contohnya Hasil Pengujian 12 (citra asli: *accuracy* 0.9800. *precision* 0.9806, *recall* 0.9800. *f1-score* 0.9799) dan Hasil Pengujian 16 (citra asli dan LBP: *accuracy* 0.9850. *precision* 0.9859, *recall* 0.9850. *f1-score* 0.9850). Secara umum, *learning rate* kecil lebih sesuai untuk kedua arsitektur karena mampu menghasilkan nilai *accuracy*, *precision*, *recall*, dan *f1-score* yang jauh lebih tinggi dan lebih stabil.

3. Secara keseluruhan, *EfficientNetB2* menunjukkan kinerja yang lebih unggul dibandingkan *MobileNetV3-Large*, baik pada penggunaan citra asli maupun pada kombinasi citra asli dan LBP, berdasarkan keempat metrik evaluasi yang digunakan. Pada citra asli, konfigurasi terbaik *MobileNetV3-Large* diperoleh pada hasil pengujian 4 LR 0.0001 dengan *accuracy* 0.9750. *precision* 0.9765, *recall* 0.9750. dan *f1-score* 0.9751, sedangkan konfigurasi terbaik *EfficientNetB2* dicapai pada hasil pengujian 12 LR 0.0001 dengan *accuracy* 0.9800. *precision* 0.9806, *recall* 0.9800. dan *f1-score* 0.9799. Pada kombinasi citra asli dan LBP, *MobileNetV3-Large* memberikan performa terbaik pada hasil pengujian 8 LR 0.0001 dengan *accuracy* 0.9800. *precision* 0.9815, *recall* 0.9800. dan *f1-score* 0.9799, sementara *EfficientNetB2* dengan LBP mencapai hasil terbaik pada hasil pengujian 16 LR 0.0001 dengan *accuracy* 0.9850. *precision* 0.9859, *recall* 0.9850. dan *f1-score* 0.9850. Berdasarkan perbandingan nilai metrik tersebut, *EfficientNetB2* terutama ketika dikombinasikan dengan LBP dan

menggunakan nilai learning rate kecil (LR 0.0001) menjadi konfigurasi yang paling optimal, sedangkan MobileNetV3-Large dengan LBP tetap kompetitif dan relevan ketika dibutuhkan arsitektur model yang lebih ringan.

5.2. Saran

Setelah seluruh rangkaian proses penelitian dilaksanakan, model yang dikembangkan belum dapat dinyatakan optimal karena masih terdapat sejumlah keterbatasan. Oleh sebab itu, diperlukan pengembangan lebih lanjut agar diperoleh hasil yang lebih baik. Berikut beberapa saran untuk penelitian selanjutnya:

1. Memperbesar ukuran dataset dan menyeimbangkan jumlah sampel antarkelas agar kemampuan generalisasi model meningkat.
2. Memperluas variasi kondisi pengambilan gambar (perangkat, jarak kamera, latar dan pencahayaan) sehingga representasi citra lebih beragam dan mendekati kondisi lapangan.
3. Menyempurnakan tahapan praproses dan augmentasi dengan penambahan operasi seperti penyesuaian kontras, saturasi, hue, blur ringan, pemotongan acak, transformasi perspektif, serta penyisipan latar acak untuk mengurangi overfitting.
4. Mengeksplorasi metode ekstraksi tekstur lain serta skema penggabungan fitur, misalnya GLCM, *Local Ternary Pattern*, sebagai pelengkap LBP.
5. Membandingkan arsitektur tambahan yang relevan, seperti *EfficientNetV2*, *MobileNetV3-Small/Medium*, *ResNet* atau *DenseNet*, dengan mempertimbangkan kompromi antara akurasi, ukuran model, dan waktu inferensi.
6. Memperluas ruang lingkup ke tugas lanjutan, misalnya klasifikasi kualitas atau tingkat kesegaran rimpang, segmentasi area rimpang, serta deteksi dalam lingkungan tidak terkontrol, agar dampak praktis penelitian semakin besar.

Halaman ini sengaja dikosongkan