

BAB V

PENUTUP

A. Kesimpulan

1. *Logistic Regression* yang dilatih menggunakan fitur hasil ekstraksi *ResNet-50* berhasil mencapai performa klasifikasi yang tinggi dan stabil pada ketiga skenario pembagian data yakni 90:10, 80:20, dan 70:30. Model *hybrid ResNet-50 + Logistic Regression* menghasilkan akurasi tertinggi sebesar 91%, dengan nilai $precision = 0.91$, $recall = 0.91$, $f1-score = 0.91$, serta $AUC = 0.97$. Hasil ini menunjukkan bahwa *Logistic Regression* mampu bekerja efektif ketika dipadukan dengan fitur representatif dari CNN, dan kinerjanya lebih unggul dibandingkan model *end-to-end ResNet-50* maupun *EfficientNet-B0*.
2. *ResNet-50* terbukti mampu mengekstraksi fitur visual yang relevan dari citra CT scan otak, sehingga memudahkan *Logistic Regression* dalam membedakan kelas stroke dan normal. Pada proses ekstraksi fitur, *ResNet-50* berhasil memproses 4.551 citra kelas stroke dengan lama waktu 31 menit 42 detik, dan 4.551 citra kelas normal dengan lama waktu 32 menit 54 detik. Hasil ekstraksi tersebut menghasilkan representasi numerik berdimensi rendah yang lebih mudah dipelajari oleh *Logistic Regression*. Hal ini terbukti meningkatkan akurasi klasifikasi dari kisaran 66–74% pada model *ResNet-50 end-to-end*, menjadi konsisten 91% pada model *hybrid*. Dengan demikian, penggunaan *ResNet-50* sebagai *feature*

extractor memberikan peningkatan signifikan terhadap kualitas hasil klasifikasi stroke berbasis citra CT scan otak.

B. Saran

1. Berdasarkan hasil penelitian ini, disarankan agar pengembangan selanjutnya dapat mengeksplorasi teknik peningkatan performa model, seperti penyesuaian arsitektur ekstraktor fitur (misalnya *fine-tuning* sebagian *layer ResNet-50*), atau menambahkan lapisan *dense* tambahan sebelum proses klasifikasi *Logistic Regression* guna memperkuat representasi fitur.
2. Untuk mengatasi penurunan akurasi yang terjadi saat proporsi data latih dikurangi, disarankan penggunaan pendekatan seperti data synthesis (misalnya SMOTE pada fitur yang diekstrak) atau menerapkan semi-supervised learning yang dapat memanfaatkan sebagian data tak berlabel untuk meningkatkan ketahanan model.
3. Penelitian lanjutan juga dapat mempertimbangkan integrasi teknik interpretasi lanjutan, seperti Grad-CAM atau SHAP, untuk membantu visualisasi area penting pada citra yang memengaruhi keputusan klasifikasi, sehingga sistem lebih mudah diterima dalam praktik medis.
4. Dataset yang digunakan dalam penelitian ini berasal dari satu sumber dan berfokus pada dua kelas (stroke dan normal). Penelitian lanjutan disarankan untuk menggunakan dataset multi-institusi dan mempertimbangkan skenario klasifikasi multi-kelas guna meningkatkan generalisasi model di lingkungan dunia nyata.