

## **BAB V**

### **PENUTUP**

#### **5.1 Kesimpulan**

Berdasarkan hasil penelitian yang telah dilakukan mengenai deteksi deepfake pada frame video menggunakan metode Convolutional Neural Network (CNN) dengan perbandingan arsitektur XceptionNet dan EfficientNet-B0, maka diperoleh beberapa kesimpulan sebagai berikut:

- 1) Penelitian berhasil membangun sistem deteksi deepfake berbasis deep learning menggunakan dua arsitektur CNN yaitu EfficientNet-B0 dan XceptionNet dengan pendekatan transfer learning. Dataset yang digunakan berasal dari Kaggle dengan kategori video real dan fake yang kemudian diekstraksi menjadi frame gambar sebagai input model. Seluruh tahapan penelitian mulai dari preprocessing, training, evaluasi model, hingga implementasi web berhasil dilakukan dengan baik menggunakan TensorFlow dan Keras pada platform Google Colab.
- 2) Penggunaan data augmentation terbukti memberikan pengaruh positif terhadap kemampuan generalisasi model dalam mendeteksi deepfake. Setelah diterapkan augmentation seperti rotation, zoom, width shift, height shift, shear, horizontal flip, dan brightness adjustment, performa model mengalami peningkatan dibandingkan skenario tanpa augmentation. Pada EfficientNet-B0, accuracy meningkat dari sekitar 72% menjadi 77%, sedangkan pada XceptionNet meningkat dari sekitar 73% menjadi 80%. Hasil tersebut menunjukkan bahwa augmentation membantu model mempelajari variasi pola wajah, pencahayaan, dan kualitas frame sehingga risiko overfitting dapat dikurangi.
- 3) Hasil penelitian menunjukkan bahwa arsitektur XceptionNet memiliki performa lebih baik dibandingkan EfficientNet-B0 dalam mendeteksi deepfake. Berdasarkan hasil pengujian, EfficientNet-B0 dengan augmentation meningkat menjadi sekitar 77%. Pada arsitektur XceptionNet, model augmentation memperoleh sekitar 80% setelah diterapkan

augmentation dan fine tuning. Hasil tersebut menunjukkan bahwa XceptionNet lebih efektif dalam menangkap pola manipulasi wajah pada frame video deepfake dibandingkan EfficientNet-B0.

- 4) Proses fine tuning memberikan kontribusi terhadap peningkatan performa model, khususnya pada XceptionNet. Fine tuning dilakukan dengan membuka sekitar 50 layer terakhir pretrained model dan menggunakan learning rate kecil sebesar  $1e-5$  agar proses pembaruan bobot lebih stabil. Setelah fine tuning diterapkan, model mengalami peningkatan performa sekitar 2–3% dibandingkan sebelum fine tuning, terutama pada metrik precision, recall, dan F1-score. Hal ini menunjukkan bahwa fine tuning membantu model menyesuaikan fitur pretrained dengan karakteristik dataset deepfake secara lebih spesifik.
- 5) Berdasarkan hasil evaluasi menggunakan confusion matrix dan classification report, model terbaik yaitu XceptionNet augmentation fine tuning mampu melakukan klasifikasi gambar real dan fake dengan cukup baik. Model memperoleh nilai accuracy sekitar 80% dengan precision dan recall yang relatif seimbang pada kedua kelas. Hal ini menunjukkan bahwa model mampu mengenali pola manipulasi wajah secara efektif meskipun masih terdapat beberapa kesalahan prediksi akibat kualitas frame, pencahayaan, blur, maupun manipulasi deepfake yang sangat realistis.
- 6) Penelitian ini juga berhasil mengimplementasikan model deep learning ke dalam aplikasi web berbasis Gradio sehingga dapat digunakan sebagai sistem deteksi deepfake secara langsung. Aplikasi web mampu melakukan upload gambar, prediksi real/fake, menampilkan confidence score, serta mendukung upload dua gambar sekaligus. Implementasi web menunjukkan bahwa model yang telah dilatih dapat diterapkan pada lingkungan nyata sebagai media demonstrasi sistem deteksi deepfake berbasis kecerdasan buatan.
- 7) Secara keseluruhan, penelitian ini membuktikan bahwa pendekatan Convolutional Neural Network dengan arsitektur XceptionNet dan teknik augmentation mampu digunakan untuk mendeteksi frame video deepfake

dengan performa yang cukup baik. Hasil penelitian juga menunjukkan bahwa kombinasi transfer learning, augmentation, dan fine tuning dapat meningkatkan kemampuan model dalam mengenali manipulasi wajah digital secara otomatis.

## 5.2 Saran

- 1) Penelitian selanjutnya disarankan menggunakan dataset dengan jumlah video yang lebih besar dan lebih beragam agar model dapat mempelajari pola deepfake secara lebih luas. Variasi dataset seperti perbedaan resolusi video, pencahayaan, ekspresi wajah, sudut pengambilan gambar, dan kualitas manipulasi perlu ditingkatkan agar model memiliki kemampuan generalisasi yang lebih baik terhadap data baru. Selain itu, penggunaan dataset dari berbagai sumber dapat membantu model menjadi lebih robust terhadap berbagai jenis manipulasi deepfake modern.
- 2) Penelitian berikutnya dapat menggunakan pendekatan berbasis video temporal atau sequence modeling seperti Long Short-Term Memory (LSTM), 3D CNN, atau Vision Transformer (ViT). Pada penelitian ini, proses klasifikasi dilakukan pada frame gambar secara individual sehingga informasi temporal antar frame belum dimanfaatkan secara maksimal. Dengan memanfaatkan hubungan antar frame pada video, sistem deteksi deepfake diharapkan mampu mengenali pola gerakan wajah, sinkronisasi bibir, dan inkonsistensi temporal yang sulit dideteksi menggunakan frame tunggal.
- 3) Pengembangan aplikasi web dapat dilakukan dengan menambahkan fitur deteksi video secara langsung tanpa perlu melakukan ekstraksi frame secara manual. Selain itu, sistem dapat dikembangkan menjadi aplikasi berbasis cloud atau mobile application agar dapat digunakan secara lebih luas oleh pengguna umum. Optimasi inference time juga perlu dilakukan agar proses prediksi menjadi lebih cepat dan ringan ketika dijalankan pada perangkat dengan spesifikasi terbatas.
- 4) Penelitian selanjutnya juga dapat melakukan eksplorasi terhadap arsitektur deep learning lain yang lebih modern seperti EfficientNetV2, ConvNeXt,

Swin Transformer, atau Hybrid CNN-Transformer untuk mengetahui performa terbaik dalam mendeteksi deepfake. Perbandingan dengan metode terbaru dapat memberikan hasil yang lebih optimal serta meningkatkan akurasi deteksi manipulasi wajah digital.

- 5) Selain fokus pada peningkatan akurasi model, penelitian selanjutnya juga disarankan memperhatikan aspek explainable AI (XAI) agar proses prediksi model dapat dijelaskan secara visual. Dengan adanya visualisasi seperti heatmap atau Grad-CAM, pengguna dapat mengetahui bagian wajah mana yang dianggap sebagai indikasi deepfake oleh model sehingga sistem menjadi lebih transparan dan mudah dipahami.
- 6) Penelitian ini masih memiliki keterbatasan pada penggunaan frame gambar sebagai unit analisis sehingga beberapa informasi temporal video belum sepenuhnya dimanfaatkan. Oleh karena itu, pengembangan penelitian berbasis video secara utuh menjadi peluang yang sangat baik untuk meningkatkan kemampuan sistem deteksi deepfake di masa mendatang.
- 7) Dengan semakin berkembangnya teknologi generative AI dan deepfake, penelitian mengenai deteksi manipulasi wajah digital perlu terus dikembangkan agar dapat membantu mencegah penyebaran informasi palsu, penipuan digital, serta penyalahgunaan media sintetis di masyarakat. Oleh karena itu, sistem deteksi deepfake berbasis deep learning diharapkan dapat menjadi salah satu solusi dalam meningkatkan keamanan dan kepercayaan terhadap konten digital.