

BAB V PENUTUP

5.1 Kesimpulan

Berdasarkan seluruh tahapan penelitian, mulai dari pengumpulan dataset, pra-pemrosesan gambar, hingga pengujian komparatif model yang telah dijabarkan pada bab-bab sebelumnya, penelitian mengenai implementasi metode Convolutional Neural Network (CNN) dengan arsitektur XceptionNet untuk deteksi artefak spasial pada video deepfake ini menghasilkan beberapa kesimpulan utama, yaitu:

1. Arsitektur XceptionNet terbukti dapat diimplementasikan dengan baik untuk mendeteksi rekayasa deepfake yang berfokus pada ruang dua dimensi (spasial). Keberhasilan deteksi ini sangat bergantung pada tahapan pra-pemrosesan awal yang presisi, khususnya penggunaan algoritma MTCNN yang mampu memotong area wajah (face cropping) secara akurat, sehingga model terhindar dari gangguan latar belakang gambar dan bisa fokus menganalisis tekstur wajah.
2. Penggunaan metode CLAHE sangat krusial dalam menangani tantangan dataset video berkompresi tinggi (standar c23). Metode ini terbukti mampu memperbaiki kontras dan mempertegas kembali jejak manipulasi visual (artefak spasial) yang buram akibat proses kompresi. Di samping itu, Augmentasi Data (rotasi, pergeseran, dan zoom) berhasil memberikan variasi yang cukup agar model tidak sekadar menghafal posisi wajah yang statis.
3. Pada pengujian Skenario 1 (Model Baseline), model yang dilatih dengan konfigurasi standar (tanpa CLAHE, tanpa augmentasi, dan menggunakan strategi Full Freeze) terbukti kurang optimal dan rentan mengalami overfitting. Hal ini terlihat jelas dari pergerakan grafik di mana akurasi pelatihan terus naik mendekati 100%, namun akurasi validasinya tertahan (stagnan) dan membentuk jarak (gap) yang lebar. Kondisi ini menyimpulkan bahwa model dasar XceptionNet kesulitan mengenali dan

melakukan generalisasi pada data manipulasi yang baru jika tidak diberikan optimasi tambahan.

4. Pada pengujian Skenario 2 (Model Optimasi Usulan), seluruh kelemahan pada skenario pertama berhasil diatasi dengan sangat baik. Penerapan strategi modifikasi arsitektur secara serentak—yakni membuka 50 layer teratas (Partial Unfreeze) sejak awal, dipadukan dengan Dropout (0.5), dan L2 Regularization pada Dense Layer—terbukti secara signifikan mampu menekan gejala overfitting. Hal ini dibuktikan dengan kurva akurasi dan loss validasi yang bergerak sangat stabil dan harmonis mengikuti data latih. Kesimpulan akhirnya, Skenario 2 merupakan solusi yang jauh lebih tangguh dan akurat dalam mendeteksi citra *deepfake* dibandingkan Skenario 1.

5.2 Saran

Berdasarkan keterbatasan yang ditemukan, beberapa saran untuk pengembangan penelitian selanjutnya adalah:

1. Integrasi analisis temporal, dengan mengombinasikan CNN dan RNN (misalnya LSTM atau GRU), guna mendeteksi inkonsistensi gerakan wajah antar frame.
2. Peningkatan ketahanan terhadap video berkualitas rendah, melalui penerapan super-resolution atau augmentasi data yang lebih beragam.
3. Optimalisasi untuk kebutuhan real-time, dengan menerapkan teknik kompresi model seperti quantization atau pruning agar sistem lebih ringan dan efisien.
4. Perluasan dan pembaruan dataset, menggunakan dataset *Deepfake* yang lebih baru dan bervariasi agar model tetap relevan terhadap teknik manipulasi terkini.