

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

1. Perbandingan arsitektur menunjukkan bahwa CNN dengan integrasi *dilated convolution* lebih efektif dibanding CNN standar dalam mendeteksi *deepfake* citra wajah. Model *dilated* CNN secara konsisten mencapai akurasi tinggi pada seluruh skenario pembagian data, berada di kisaran 81–87%, dengan akurasi tertinggi namun teridentifikasi *overfitting* karena data latih yang kecil pada skema 90:10 (87%) dan skenarip terbaik dengan hasil optimal yang kredibel pada 80:20 (85%). Sementara itu, CNN standar mencatat akurasi di kisaran 81–84%, dengan tren peningkatan yang lebih lambat dan stabilitas yang lebih rendah pada skema menengah (60:40 hingga 70:30). Pola ini memperkuat tesis bahwa perluasan *receptive field* melalui *dilated convolution* membantu model menangkap konteks spasial global tanpa kehilangan detail lokal, sehingga meningkatkan kemampuan dalam mengenali manipulasi halus pada wajah.
2. Kinerja antar kelas menunjukkan keseimbangan yang baik dan membaik seiring peningkatan data latih. Berdasarkan confusion matrix dan classification report pada berbagai skema, precision dan recall untuk kelas *fake* dan *real* cenderung simetris pada skema yang lebih matang (80:20). Pada skema awal, model sempat menunjukkan kecenderungan lebih sensitif terhadap kelas *fake* ($\text{recall}_{fake} > \text{recall}_{real}$), namun perbedaan tersebut menyempit ketika porsi data latih meningkat. Hal ini menunjukkan peningkatan kemampuan generalisasi model, yang semakin seimbang dalam membedakan antara citra asli dan palsu.

5.2. Saran

1. Menerapkan k-fold cross-validation atau repeated hold-out dan laporkan deviasi standar/interval kepercayaan untuk akurasi, precision/recall/F1 per kelas. Tambahkan ROC-AUC/PR-AUC untuk memberi gambaran di berbagai ambang (threshold).
2. Melakukan penyetelan threshold guna mengendalikan trade-off precision – recall sesuai biaya salah klasifikasi (mis. menekan false negative *real*).

Sertakan kalibrasi probabilitas (Platt/Isotonic) agar skor lebih reliabel pada skenario operasional.

3. Uji variasi dilation rate, jumlah/lokasi *dilated layers*, serta kombinasi dengan average/max *pooling* dan *Dropout* rate. Cantumkan analisis kompleksitas (parameter, FLOPs) vs kinerja untuk menjustifikasi konfigurasi akhir.
4. Perluas augmentasi (blur, kompresi, color jitter, jpeg artifacts) dan uji robustness terhadap skenario dunia nyata (resolusi rendah, noise, post-processing). Tambahkan dataset lintas domain agar model tahan pergeseran distribusi.
5. Untuk tahap lanjut, pertimbangkan integrasi isyarat temporal (video-level cues), frequency artifacts, atau physiological signals (mis. eye-blinking rate) guna meningkatkan deteksi pada manipulasi yang sangat halus.
6. Jika diarahkan ke penggunaan nyata data primer, siapkan pipeline MLOps (monitoring drift, retraining periodik) dan kebijakan etis terkait false alarm dan hak privasi, mengingat konsekuensi sosial dari deteksi *deepfake*.