

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan rangkaian analisis dan studi yang telah dilakukan, dapat disimpulkan bahwa:

1. Dari keempat variasi model *EfficientNetB0* yang diuji, yaitu *EfficientNetB0_NoAug_NoCA*, *EfficientNetB0_Aug_NoCA*, *EfficientNetB0_CA_NoAug*, dan *EfficientNetB0_Aug_CA*, variasi model *EfficientNetB0* yang menggunakan teknik augmentasi tanpa penambahan *channel attention* (*EfficientNetB0_Aug_NoCA*) merupakan yang paling baik dengan nilai akurasi tertinggi untuk semua kondisi pencahayaan, nilai akurasi tersebut adalah 88% untuk kondisi gelap, 86% untuk kondisi sedang, 90% untuk kondisi terang, dan secara keseluruhan (rata-rata) pada semua kondisi pencahayaan adalah 88%.
2. Untuk klasifikasi pada kondisi pencahayaan yang beragam (gelap, sedang, terang) dalam penelitian ini, penambahan teknik augmentasi yang digunakan dapat lebih meningkatkan akurasi model secara signifikan pada *backbone EfficientNetB0*. Sedangkan penambahan *channel attention* tidak konsisten dalam meningkatkan akurasi model, dan justru lebih sering memperburuk akurasi model *EfficientNetB0*. Hal ini ditunjukkan dengan nilai akurasi *backbone EfficientNetB0* murni secara keseluruhan sebesar 67%, jika ditambahkan dengan teknik augmentasi (tanpa CA) nilai akurasi menjadi 88%, tetapi ketika ditambahkan *channel attention* (tanpa augmentasi) nilai akurasi menjadi 59%.
3. Model *EfficientNetB0_Aug_NoCA* selain merupakan model yang memiliki kinerja paling baik dari pengujian *offline*, juga sudah bisa dikatakan memiliki kinerja yang cukup baik juga ketika diuji secara *online/live/real-time* dengan diimplementasikan kedalam *prototype early warning system* berbasis *computer vision*. Hal ini ditunjukkan dengan sebesar 90% dari *frame* yang berhasil ditangkap secara *real-time* dalam kondisi gelap dapat diklasifikasikan dengan benar, 87% dalam kondisi sedang, dan 97% dalam kondisi terang. Kemudian

rata-rata nilai *latency* dalam setiap kondisi pencahayaan juga berkisar sekitar 115-116 ms dan sekitar 8 *frame per second* sistem/model dapat menangkap *frame* dan memberikan hasil klasifikasi baru.

4. Kondisi pencahayaan dapat mempengaruhi kinerja model dalam penelitian ini, semakin terang pencahayaan, semakin lebih baik juga kinerjanya. Hal ini ditunjukkan dengan kesalahan klasifikasi kelas yang dianggap sulit oleh model secara *real-time*, yaitu kelas 'c8', semakin menurun seiring dengan terangnya pencahayaan.

5.2. Saran Pengembangan

Berikut adalah beberapa saran yang dapat diambil untuk pengembangan penelitian selanjutnya berdasarkan temuan yang ada pada penelitian ini:

1. Penelitian selanjutnya dapat meningkatkan variasi subjek untuk dataset primer.
2. Penelitian selanjutnya dapat menggunakan alat ukur standar industri seperti digital lux meter untuk memvalidasi nilai lux dalam mengukur intensitas pencahayaan.
3. Penelitian selanjutnya dapat melakukan eksperimen dengan kegelapan ekstrem seperti dibawah 20 lux dan dapat menggunakan kamera berbasis *night vision/infrared*.
4. Penelitian selanjutnya dapat menggunakan arsitektur spatio-temporal ringan seperti *EfficientNetB0+LSTM/GRU* untuk membantu kinerja klasifikasi secara *real-time*, atau arsitektur 3D CNN, dan bisa juga menggunakan arsitektur berbasis *vision transformer* seperti *Video Swin Transformer* jika sumber daya perangkat keras mencukupi.
5. Penelitian selanjutnya dapat mengimplementasikan teknik *Temporal Smoothing (Moving Average)* pada GUI untuk mengurangi risiko *flickering*.
6. Penelitian selanjutnya dapat menggunakan *framework* berbasis GPU seperti NVIDIA CUDA Toolkit, cuDNN, dan NVIDIA TensorRT untuk sistem yang memiliki *dedicated GPU NVIDIA*.