

## ABSTRAK

Pengenalan ekspresi wajah pada dataset *in-the-wild* seperti FER-2013 memiliki tantangan utama berupa variasi pencahayaan ekstrem, oklusi, dan ketidakseimbangan kelas data. Penelitian ini menerapkan metode *Deep Learning* dengan teknik *Transfer Learning* menggunakan arsitektur VGG16 yang dimodifikasi. Kebaruan (*novelty*) yang diusulkan adalah integrasi mekanisme atensi *Squeeze-and-Excitation* (SE-Block) untuk meningkatkan sensitivitas model terhadap fitur wajah penting, serta penerapan strategi *Aggressive Fine-Tuning* dengan optimasi *Label Smoothing*. Metode ini menguji dua skenario eksperimental: Skenario 1 (*Baseline*) menggunakan VGG16 standar dengan bobot beku (*frozen*), dan Skenario 2 (*Optimized*) menerapkan pencairan bobot (*unfreezing*) pada lapisan konvolusi tingkat tinggi yang dilengkapi SE-Block. Pelatihan dilakukan menggunakan teknik *Mixed Precision* untuk efisiensi komputasi GPU dan penyeimbangan bobot kelas (*Class Weights*) untuk menangani masalah data tidak seimbang. Hasil pengujian menunjukkan bahwa integrasi *SE-Block* dan strategi *fine-tuning* pada Skenario 2 mampu meningkatkan akurasi validasi secara signifikan menjadi 66,9%, yaitu mengalami peningkatan sebesar 15,2% dibandingkan metode *baseline* (51,7%) serta menunjukkan ketahanan (*robustness*) yang lebih baik terhadap variasi ekspresi.

**Kata Kunci:** *Deep Learning, FER-2013, Fine-Tuning, SE-Block, Transfer Learning, VGG16.*

## ABSTRACT

*Facial expression recognition on in-the-wild datasets such as FER-2013 poses major challenges in the form of extreme lighting variations, occlusions, and data class imbalance. This study applies a Deep Learning method with Transfer Learning techniques using a modified VGG16 architecture. The proposed novelty is the integration of the Squeeze-and-Excitation (SE-Block) attention mechanism to improve the model's sensitivity to important facial features, as well as the application of an Aggressive Fine-Tuning strategy with Label Smoothing optimization. This method tests two experimental scenarios: Scenario 1 (Baseline) uses standard VGG16 with frozen weights, and Scenario 2 (Optimized) applies weight unfreezing to high-level convolutional layers equipped with SE-Block. Training was conducted using the Mixed Precision technique for GPU computational efficiency and class weight balancing to address the issue of imbalanced data. The test results show that the integration of SE-Block and the fine-tuning strategy in Scenario 2 can significantly improve the validation accuracy to 66.9%, an increase of 15.2% compared to the baseline method (51.7%) and shows better robustness against expression variations.*

**Keywords:** *Deep Learning, FER-2013, Fine-Tuning, SE-Block, Transfer Learning, VGG16.*