

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Penelitian ini menunjukkan bahwa Mel-spectrogram dapat digunakan secara efektif sebagai fitur untuk klasifikasi suara pasien Healthy Control (HC) dan Major Depressive Disorder (MDD). Mel-spectrogram mampu merepresentasikan informasi frekuensi dan waktu dari sinyal suara, yang penting dalam mendeteksi karakteristik emosional terkait kondisi mental.

1. Mel-Spectrogram sebagai Fitur Klasifikasi

Mel-spectrogram terbukti dapat digunakan sebagai fitur yang efektif untuk klasifikasi suara pasien HC dan MDD. Fitur ini mampu merepresentasikan informasi frekuensi dan waktu dari sinyal suara dengan baik, yang sangat penting dalam mendeteksi karakteristik emosional yang berhubungan dengan kondisi mental. Penggunaan Mel-spectrogram membantu dalam menangkap karakteristik penting dari sinyal audio yang berkaitan dengan intonasi, nada, dan ritme, yang semuanya dapat menjadi indikator emosional dan kondisi mental seseorang.

2. Performa Model ShuffleNet

Model ShuffleNet dengan menggunakan *optimizer* Adam memiliki performa yang cukup baik dengan akurasi sekitar 69.34% pada data pelatihan. Meskipun terdapat fluktuasi pada akurasi validasi yang menunjukkan adanya potensi overfitting, *optimizer* Adam menunjukkan hasil yang lebih baik dibandingkan SGDM dalam pelatihan ShuffleNet, terutama dalam klasifikasi kelas MDD. ShuffleNet dengan *optimizer* Adam menunjukkan precision sebesar 80.4% untuk kelas HC dan 57.5% untuk kelas MDD, dengan recall masing-masing 43.3% dan 87.9%. Nilai F1-score adalah 56% untuk HC dan 70% untuk MDD.

3. Performa Model InceptionV3

Model InceptionV3 menunjukkan performa yang lebih baik dibandingkan ShuffleNet. Dengan menggunakan *optimizer* Adam, InceptionV3 mencapai akurasi pelatihan hampir sempurna sebesar 99.75% dan akurasi validasi sebesar

93.40%. InceptionV3 dengan *optimizer* Adam menunjukkan kemampuan generalisasi yang lebih baik serta kinerja yang lebih seimbang dalam klasifikasi kedua kelas (HC dan MDD). Precision untuk InceptionV3 dengan *optimizer* Adam adalah 90% untuk HC dan 98% untuk MDD, dengan recall masing-masing 99% dan 87%. Nilai F1-score adalah 94% untuk HC dan 92% untuk MDD.

4. Perbandingan dengan Model Sebelumnya

Model ShuffleNet dengan menggunakan *optimizer* Adam memiliki performa yang cukup baik dengan akurasi sekitar 69.34% pada data pelatihan. Meskipun terdapat fluktuasi pada akurasi validasi yang menunjukkan potensi *overfitting*, *optimizer* Adam menunjukkan hasil yang lebih baik dibandingkan SGDM dalam pelatihan ShuffleNet, terutama dalam klasifikasi kelas MDD.

Berdasarkan hasil penelitian, fitur mel-spectrogram terbukti efektif dalam mengklasifikasikan subjek dengan Major Depressive Disorder (MDD) dan Healthy Control (HC). Representasi mel-spectrogram mampu menangkap informasi temporal dan spektral dari sinyal audio, yang sangat penting untuk mendeteksi pola-pola yang mungkin mengindikasikan keberadaan depresi. Penelitian ini menunjukkan bahwa mel-spectrogram dapat diandalkan untuk digunakan sebagai fitur dalam model klasifikasi audio. Implementasi Convolutional Neural Networks (CNN) dalam klasifikasi suara untuk deteksi depresi telah menunjukkan peningkatan performa yang signifikan. Model InceptionV3, khususnya, menunjukkan akurasi pelatihan mencapai 99.75% dan akurasi validasi sebesar 93.40%. Ini menunjukkan bahwa CNN dapat secara efektif meningkatkan performa klasifikasi dengan memanfaatkan kemampuan mereka untuk menangkap dan mengolah fitur kompleks dari mel-spectrogram.

Penggunaan transfer learning dengan model InceptionV3 menunjukkan peningkatan performa yang signifikan dibandingkan dengan model yang dilatih dari awal. Transfer learning memungkinkan model untuk memanfaatkan pengetahuan yang diperoleh dari dataset besar yang serupa, sehingga meningkatkan akurasi dan efisiensi pelatihan. Dalam penelitian ini, model InceptionV3 yang menggunakan transfer learning mencapai hasil yang sangat

baik, membuktikan bahwa transfer learning dapat meningkatkan performa klasifikasi suara untuk deteksi depresi.

5.2 Saran

Untuk penelitian selanjutnya, disarankan untuk menggunakan lebih banyak data. Penambahan jumlah data dapat membantu meningkatkan performa model dan mengurangi overfitting. Data yang lebih banyak memungkinkan model untuk belajar dari variasi yang lebih luas dalam sinyal suara, sehingga meningkatkan kemampuan generalisasi.

Selain itu, melakukan pra-pemrosesan pada sinyal sebelum dijadikan Mel-spectrogram dapat meningkatkan kualitas fitur yang diekstraksi. Beberapa langkah pra-pemrosesan yang disarankan termasuk pemotongan data untuk menghilangkan bagian yang tidak relevan, penyesuaian volume untuk konsistensi intensitas suara, dan penggunaan gain untuk mengurangi noise. Terakhir, melakukan augmentasi data pada sinyal sebelum diubah menjadi Mel-spectrogram dapat membantu dalam memperkaya dataset dan mengurangi overfitting. Teknik augmentasi seperti penambahan noise, shifting, stretching, dan pitch adjustment dapat digunakan untuk menciptakan variasi tambahan dalam data pelatihan. Dengan mengikuti saran-saran di atas, diharapkan dapat meningkatkan performa model dalam klasifikasi suara untuk deteksi depresi, serta memberikan kontribusi yang lebih signifikan dalam pengembangan alat diagnostik yang lebih efektif dan dapat diandalkan.