

## **BAB V**

### **KESIMPULAN DAN SARAN**

Bab ini merangkum temuan dari penelitian yang telah dilakukan serta memberikan saran pengembangan penelitian selanjutnya. Kesimpulan disusun berdasarkan temuan empiris selama proses analisis, sementara saran difokuskan pada penguatan metodologi dan perluasan aplikasi sistem.

#### **5.1 Kesimpulan**

Berdasarkan rangkaian analisis dan eksperimen yang telah dilakukan, diperoleh sejumlah simpulan yang merangkum temuan utama dalam menjawab rumusan masalah. Simpulan tersebut mencerminkan tingkat keberhasilan pendekatan yang diterapkan, kualitas hasil yang diperoleh, serta kontribusi penelitian dalam mengidentifikasi pola emosional berbasis sinyal fisiologis secara komputasional.

##### **5.1.1 Keberhasilan Pengembangan Teknik Analisis *Big Data* untuk Pemrosesan Sinyal sEMG Wajah**

Pengembangan teknik analisis *big data* untuk pemrosesan sinyal sEMG wajah berhasil diimplementasikan menggunakan Apache Spark dalam lingkungan komputasi terdistribusi. Penerapan teknologi ini merupakan capaian signifikan dalam mengatasi keterbatasan komputasi yang menjadi kendala pada studi pendahuluan. Pendekatan ini memungkinkan pemrosesan seluruh *dataset* berjumlah lebih dari 30 juta baris data dengan ukuran total  $\pm 13,9$  GB secara efisien tanpa reduksi data, seperti pada studi pendahuluan. Keberhasilan pengembangan ini menunjukkan bahwa teknologi komputasi terdistribusi Apache Spark mampu menangani kompleksitas data sinyal fisiologis dalam skala besar, yang sebelumnya menjadi hambatan utama dalam analisis komprehensif sinyal sEMG wajah untuk identifikasi pola emosi.

### 5.1.2 Efektivitas *Big Data* dalam Meningkatkan Kualitas Identifikasi Pola Emosi

Pemanfaatan teknologi *big data* dalam penelitian ini terbukti efektif meningkatkan kualitas identifikasi pola emosi berdasarkan *dataset* EmgDataVR. Sistem berhasil menganalisis keseluruhan *dataset* (100%) dibandingkan dengan studi pendahuluan yang hanya memanfaatkan 0,196% dari total data. Dengan pendekatan pemrosesan terdistribusi, sistem mampu mengelola data berskala besar yang menghasilkan *silhouette coefficient* sebesar 0,8639 menggunakan algoritma Bisecting K-Means. Meskipun nilai tersebut tidak secara langsung dibandingkan dengan studi pendahuluan karena perbedaan jumlah data dan algoritma yang digunakan, hasil ini tetap mencerminkan struktur *cluster* yang lebih terdefinisi. Hal ini menunjukkan bahwa penerapan teknologi *big data* tidak hanya memperluas cakupan analisis, tetapi juga identifikasi pola emosi yang lebih komprehensif dan representatif terhadap keseluruhan data sinyal sEMG wajah.

### 5.1.3 Keunggulan Komputasi Terdistribusi dalam Pemrosesan *Big Data* sEMG

Implementasi komputasi terdistribusi dalam penelitian ini berhasil menganalisis 100% *dataset*, yang terdiri dari 30.327.000 baris, dalam waktu 3 menit 12 detik menggunakan *cluster* Apache Spark. Hal ini menunjukkan peningkatan signifikan dibandingkan dengan studi pendahuluan yang hanya mampu memproses 0,196% dari total data (sekitar 36.000 baris) akibat keterbatasan sumber daya pada Google Colab (12 GB RAM, 2 CPU core). Infrastruktur komputasi terdistribusi dengan 1 *master node* dan 9 *worker nodes* terbukti mampu menangani *big data* sinyal sEMG, sekaligus memberikan skalabilitas tinggi dalam analisis data fisiologis dalam skala besar.

Selain kesimpulan yang menjawab rumusan masalah, penelitian ini mengungkap temuan tambahan yang muncul selama proses penelitian. Temuan ini memperluas cakupan pemahaman terhadap dinamika proses serta membuka peluang untuk pengembangan penelitian lebih lanjut.

#### 5.1.4 Optimalisasi Konfigurasi *Clustering*

Hasil evaluasi menunjukkan bahwa konfigurasi Bisecting K-Means dengan dua *cluster* memberikan kualitas *clustering* paling optimal, dengan nilai *silhouette coefficient* sebesar 0,8639. Hasil ini tidak dapat dibandingkan secara langsung dengan studi pendahuluan yang menggunakan K-Means pada *subset* data (30.771 baris) dan memperoleh *silhouette coefficient* sebesar 0,672. Namun, nilai *silhouette coefficient* yang lebih tinggi dalam penelitian ini menunjukkan bahwa pendekatan dan konfigurasi yang diterapkan mampu membentuk struktur *cluster* yang lebih baik pada skala data besar.

#### 5.1.5 Identifikasi Pola Emosi Berdasarkan Tingkat *Arousal*

Pola emosi yang dihasilkan dari proses *clustering* mengindikasikan adanya dua kondisi utama berdasarkan tingkat *arousal*, yaitu *Low Arousal* (cluster 0) dan *High Arousal* (cluster 1). Pembagian ini mencerminkan spektrum aktivasi emosional yang dapat terdeteksi melalui sinyal sEMG wajah, dimana setiap kondisi memiliki karakteristik fisiologis yang berbeda. Aktivasi signifikan pada otot *Zygomaticus* dan *Orbicularis* pada *cluster* 1 sesuai dengan AU6 (Cheek Raiser) dan AU12 (Lip Corner Puller) dalam teori Ekman, yang merepresentasikan ekspresi kegembiraan. Temuan ini menunjukkan korelasi yang kuat antara pola aktivasi otot wajah dan manifestasi emosi positif, serta mengkonfirmasi bahwa sistem mampu mengenali dan membedakan pola aktivasi otot spesifik untuk kondisi emosional.

#### 5.1.6 Kontribusi Kuantifikasi pada Aktivasi Nilai Sinyal sEMG Amplitudo

Penelitian ini berhasil mengkuantifikasi aktivasi otot wajah berdasarkan nilai sinyal sEMG amplitudo yang terkait dengan *Action Units* (AU) secara numerik, sehingga memberikan kontribusi metodologis yang signifikan dalam analisis emosi berbasis sinyal fisiologis. Kontribusi ini melengkapi studi pendahuluan yang bersifat deskriptif dengan menyediakan dasar kuantitatif untuk interpretasi ekspresi emosi berbasis sinyal sEMG. Kuantifikasi ini memungkinkan analisis yang lebih objektif, terukur, dan dapat direproduksi menggantikan pendekatan subjektif yang sebelumnya dominan dalam interpretasi sinyal sEMG. Dengan tersedianya nilai

ambang numerik (threshold), penelitian ini membuka peluang untuk pengembangan sistem otomatis yang dapat mengklasifikasikan emosi sehingga meningkatkan reliabilitas dan validitas hasil analisis emosi.

## 5.2 Saran

Meskipun penelitian ini telah berhasil mengembangkan sistem identifikasi pola emosi berbasis sinyal sEMG dengan pendekatan *big data* menggunakan Apache Spark, terdapat beberapa keterbatasan yang tidak serta-merta melemahkan kontribusi penelitian, tetapi menjadi ruang strategis untuk perbaikan dan penyempurnaan ke depan. Beberapa keterbatasan yang teridentifikasi dalam penelitian ini meliputi:

1. Cakupan algoritma *clustering* yang masih terbatas pada dua metode (K-Means dan Bisecting K-Means), sehingga belum menggambarkan keseluruhan variasi struktur data emosional yang mungkin kompleks atau non-linier.
2. Ketidakkonsistenan parameter initial *centroid*, khususnya pada algoritma K-Means, yang dapat menyebabkan variasi hasil antar eksekusi dan mempengaruhi stabilitas evaluasi.
3. Pendekatan personalisasi belum diterapkan, padahal ekspresi wajah dan aktivasi otot memiliki karakteristik individual yang berbeda.
4. Penggunaan satu modalitas sinyal (sEMG) tanpa integrasi multimodal, yang berpotensi membatasi deteksi emosi dalam konteks yang lebih luas, terutama emosi yang tidak secara langsung tercermin dalam ekspresi wajah.

Berdasarkan keterbatasan tersebut, berikut adalah saran pengembangan yang dapat dipertimbangkan untuk penelitian selanjutnya.:

### 5.2.1 Optimalisasi Parameter *Initial Centroid*

Penetapan parameter *initial centroid* pada algoritma K-Means merupakan langkah untuk memastikan konsistensi dan hasil penelitian dapat direproduksi. Pemilihan *centroid* awal secara acak berisiko menimbulkan fluktuasi nilai *silhouette coefficient* pada setiap proses eksekusi, yang berpotensi menghasilkan

inkonsistensi interpretasi pola emosi. Penetapan parameter ini akan mengeliminasi variabilitas yang tidak diinginkan dalam proses *clustering*, sehingga memungkinkan perbandingan hasil yang lebih konsisten antar eksperimen. Implementasi *initial centroid* yang tetap juga akan memfasilitasi evaluasi performa algoritma secara lebih akurat.

### 5.2.2 Implementasi Algoritma *Clustering* Alternatif

Penerapan algoritma *clustering* tambahan seperti Gaussian Mixture Model (GMM) atau Spectral Clustering untuk membandingkan performa terhadap K-Means dan Bisecting K-Means, serta untuk mengevaluasi keberagaman struktur data emosional yang mungkin tidak linear. Implementasi algoritma alternatif ini penting mengingat bahwa setiap algoritma memiliki asumsi dan karakteristik yang berbeda dalam menangani distribusi data. GMM dapat menangani *cluster* dengan bentuk dan ukuran yang bervariasi, sementara Spectral Clustering lebih efektif untuk data dengan struktur non-linear atau kompleks. Perbandingan performa antar algoritma akan memberikan *insight* yang lebih komprehensif tentang struktur data sinyal sEMG wajah dan memungkinkan pemilihan metode yang paling sesuai dengan karakteristik data emosional yang dianalisis.

### 5.2.3 Integrasi Sinyal Fisiologis Multimodal

Pendekatan multimodal yang menggabungkan sinyal sEMG dengan sinyal fisiologis lain seperti EEG atau detak jantung, direkomendasikan untuk meningkatkan akurasi deteksi emosi. Setiap jenis sinyal membawa informasi unik yang dapat saling melengkapi dan mengurangi keterbatasan masing-masing modalitas. Kombinasi sEMG wajah yang menangkap ekspresi fisik dengan EEG yang merekam aktivitas otak atau sinyal kardiovaskular yang mencerminkan respons otonom dapat menghasilkan sistem deteksi emosi yang lebih *robust* dan akurat. Pendekatan ini juga dapat mengurangi *false positive* dan *false negative* yang mungkin terjadi ketika hanya mengandalkan satu jenis sinyal fisiologis.

#### 5.2.4 Personalisasi Model Adaptif

Penerapan pendekatan seperti penyesuaian individual (personalization model) atau *adaptive clustering* disarankan untuk menangani variabilitas ekspresi antar individu. Setiap individu memiliki karakteristik ekspresi emosi yang berbeda, baik dari segi intensitas maupun bentuk aktivasi otot fisiologis. Model personalisasi memungkinkan sistem melakukan kalibrasi awal terhadap *baseline* masing-masing pengguna dan menyesuaikan parameter *clustering* secara dinamis. Pendekatan *adaptive clustering* juga memungkinkan sistem untuk terus belajar dari data pengguna secara berkelanjutan, sehingga akurasi deteksi emosi dapat meningkat seiring waktu dan penggunaan. Pendekatan ini dapat menciptakan sistem yang responsif terhadap keragaman respons emosional antar individu.

#### 5.2.5 Prospek Pengembangan Aplikasi

Penelitian ini memiliki potensi untuk menjadi fondasi pengembangan sistem pengenalan emosi berbasis fisiologi yang dapat diaplikasikan secara *real-time*. Implementasi pendekatan *big data* dalam pengolahan sinyal sEMG serta keberhasilan dalam melakukan kuantifikasi aktivitas otot membuka peluang penerapan di berbagai bidang. Dalam konteks interaksi manusia-komputer, sistem ini dapat diintegrasikan untuk menciptakan antarmuka adaptif yang mampu merespons kondisi emosional pengguna secara empatik. Di bidang psikologi dan kesehatan mental, sistem ini dapat dimanfaatkan sebagai alat bantu objektif untuk memantau kondisi emosional pasien, mendeteksi gangguan afektif secara dini, atau mengevaluasi efektivitas terapi secara berkelanjutan.