

## BAB V PENUTUP

### 5.1 Kesimpulan

Berdasarkan hasil penelitian dan analisis yang telah dilakukan terhadap implementasi metode *Support Vector Machine* (SVM) dan *Least Squares Support Vector Machine* (LSSVM) untuk klasifikasi gangguan tidur, dapat ditarik kesimpulan yang menjawab identifikasi masalah yang telah dirumuskan pada bab sebelumnya:

#### 1. Performa Metode SVM dalam Klasifikasi Gangguan Tidur

Hasil penelitian menunjukkan bahwa metode *Support Vector Machine* (SVM) memberikan performa yang sangat baik dalam klasifikasi gangguan tidur berdasarkan *The Sleep Health and Lifestyle Dataset*. SVM berhasil mencapai akurasi sebesar 93,33% dengan performa yang sangat unggul pada kelas mayoritas (*None*) di mana mencatat *precision* 1,00, *recall* 0,98, dan *F1-score* 0,99. Untuk klasifikasi gangguan tidur spesifik, SVM menunjukkan konsistensi yang baik pada kelas *Insomnia* dan *Sleep Apnea* dengan *F1-score* masing-masing 0,87 dan 0,85. Secara keseluruhan, SVM mencatatkan *precision* rata-rata tertimbang sebesar 94%, *recall* 93,33%, dan *F1-score* 93,43%. Keunggulan SVM terletak pada kemampuannya membentuk *decision boundary* yang adaptif terhadap distribusi data dan memberikan performa tinggi pada kelas mayoritas dengan stabilitas yang baik meski menggunakan parameter *default*.

#### 2. Performa Metode LSSVM dalam Klasifikasi Gangguan Tidur

Metode *Least Squares Support Vector Machine* (LSSVM) juga menunjukkan performa yang sangat baik dalam klasifikasi gangguan tidur menggunakan *dataset* yang sama, dengan mencapai akurasi sebesar 93,33%. LSSVM menunjukkan keunggulan dalam stabilitas performa antar kelas dengan distribusi kesalahan yang lebih merata dibandingkan SVM. Metode ini mencatat *recall* sempurna (1,00) pada kelas *None* dan *precision* sempurna (1,00) pada kelas *Sleep Apnea*. Secara keseluruhan, LSSVM mencatatkan *precision* rata-rata tertimbang sebesar 93,59%, *recall* 93,33%, dan *F1-score* 93,19%. Keunggulan

LSSVM terletak pada kemampuannya memberikan klasifikasi yang lebih seimbang pada ketiga kategori gangguan tidur, efisiensi komputasi yang lebih baik melalui transformasi masalah *optimasi kuadratik* menjadi sistem *persamaan linier*, serta konsistensi dalam menangani data *multi-class* yang tidak seimbang.

### 3. Perbandingan Kinerja SVM dan LSSVM untuk Klasifikasi Gangguan Tidur

Berdasarkan perbandingan antara SVM dan LSSVM, keduanya menunjukkan akurasi yang sama yaitu 93,33%, menandakan efektivitas yang sebanding dalam klasifikasi gangguan tidur. SVM sedikit lebih unggul dalam *precision* (94% vs 93,59%) dan *F1-score* (93,43% vs 93,19%), serta lebih baik dalam mengenali kelas mayoritas. Sementara itu, LSSVM menunjukkan performa yang lebih seimbang antar kelas dan unggul dalam efisiensi komputasi karena menggunakan sistem persamaan linier, sehingga lebih cocok untuk aplikasi *real-time*.

## 5.2 Saran

Berdasarkan hasil dan pembahasan yang telah diperoleh, beberapa saran yang dapat diberikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Perlu dilakukan ekspansi *dataset* dengan jumlah sampel yang lebih besar dan variasi demografis yang lebih beragam, termasuk rentang usia yang lebih luas dan berbagai latar belakang. Hal ini penting untuk meningkatkan generalisasi model terhadap populasi yang lebih luas.
2. Optimasi lebih lanjut dapat dilakukan melalui *hyperparameter tuning* menggunakan teknik seperti *Grid Search* atau *Bayesian Optimization* untuk memaksimalkan potensi kedua algoritma. Selain itu, pengembangan pendekatan *ensemble learning* yang menggabungkan kekuatan berbagai algoritma dapat dipertimbangkan untuk meningkatkan akurasi dan *robustness* model.
3. Integrasi dengan teknologi modern seperti data dari *wearable devices* dan sensor *IoT* dapat memberikan informasi *real-time* yang lebih akurat mengenai pola tidur dan aktivitas harian. Pengembangan fitur tambahan yang lebih spesifik secara klinis dengan melibatkan *expertise* tenaga medis juga dapat meningkatkan relevansi model dalam praktik medis.

4. Validasi eksternal menggunakan *dataset* dari sumber yang berbeda perlu dilakukan untuk menguji generalisasi model. Implementasi uji klinis terbatas dalam lingkungan medis yang sesungguhnya juga diperlukan untuk mengevaluasi efektivitas sistem secara praktis.
5. Pengembangan antarmuka pengguna yang *user-friendly* dan integrasi dengan sistem rekam medis elektronik akan memudahkan adopsi teknologi ini oleh tenaga kesehatan. Pengembangan aplikasi *mobile* untuk *self-assessment* juga dapat memberikan manfaat bagi masyarakat umum dalam *monitoring* kesehatan tidur mereka.
6. Aspek etis dan regulasi perlu diperhatikan, termasuk perlindungan data pribadi dan medis sesuai regulasi yang berlaku, serta pengembangan strategi untuk mengurangi bias dalam model. Persiapan dokumentasi dan validasi untuk mendapatkan persetujuan regulasi sebagai *medical device* atau *clinical decision support system* juga menjadi pertimbangan penting untuk implementasi yang lebih luas di masa depan.

Dengan mempertimbangkan saran-saran di atas, diharapkan penelitian lanjutan dapat menghasilkan sistem klasifikasi gangguan tidur yang lebih akurat, efisien, dan aplikatif dalam konteks klinis dan teknologi kesehatan digital masa depan.