

# Deteksi Gangguan Tidur Menggunakan Support Vector Machine pada Aplikasi Web Streamlit

Satria Dava Riansa<sup>\*1</sup>, Aria Hendrawan<sup>2</sup>

Universitas Semarang, Semarang, Jawa Tengah, Indonesia 50196

e-mail: <sup>1</sup>satriadava2909@gmail.com, <sup>2</sup>ariahendrawan@usm.ac.id

\*Penulis Korespondensi

Diterima: 4 Mei 2026; Direvisi: 19 Mei 2026; Disetujui: 21 Mei 2026

## Abstrak

Gangguan tidur menjadi salah satu permasalahan kesehatan yang dapat berdampak pada kondisi fisik, mental, dan produktivitas individu. Kondisi ini dapat dipengaruhi oleh faktor gaya hidup maupun fisiologis, seperti durasi tidur, kualitas tidur, tingkat stres, aktivitas fisik, detak jantung, dan tekanan darah. Penelitian ini bertujuan untuk menerapkan metode Support Vector Machine (SVM) dalam mengklasifikasikan gangguan tidur ke dalam tiga kategori, yaitu normal, insomnia, dan sleep apnea, serta membangun aplikasi web berbasis Streamlit untuk mendukung proses prediksi secara interaktif. Dataset yang digunakan adalah Sleep Health and Lifestyle yang diperoleh dari Kaggle. Tahapan penelitian mencakup pra-pemrosesan data, normalisasi menggunakan StandardScaler, pelatihan model SVM dan lima algoritma pembandingan, serta hyperparameter tuning untuk memperoleh performa terbaik. Hasil pengujian menunjukkan bahwa model SVM dengan kernel poly menghasilkan akurasi sebesar 97,33% dan F1-score makro sebesar 0,9569. Model terbaik kemudian diimplementasikan ke dalam aplikasi web yang mampu menampilkan hasil klasifikasi beserta probabilitas tiap kelas, sehingga dapat dimanfaatkan sebagai media skrining awal gangguan tidur yang mudah digunakan.

**Kata kunci:** gangguan tidur, support vector machine, klasifikasi, machine learning, streamlit

## Abstract

Sleep disorders are health problems that may affect an individual's physical condition, mental well-being, and daily productivity. These conditions can be influenced by lifestyle and physiological factors, such as sleep duration, sleep quality, stress level, physical activity, heart rate, and blood pressure. This study aims to apply the Support Vector Machine (SVM) method to classify sleep disorders into three categories, namely normal, insomnia, and sleep apnea, as well as to develop a Streamlit-based web application to support interactive prediction. The dataset used in this study is the Sleep Health and Lifestyle dataset obtained from Kaggle. The research stages include data preprocessing, normalization using StandardScaler, model training using SVM and five comparison algorithms, and hyperparameter tuning to obtain the best performance. The evaluation results show that the SVM model with a poly kernel achieves an accuracy of 97.33% and a macro F1-score of 0.9569. The best model is then implemented into a web application that displays classification results along with the probability of each class, making it useful as an accessible early screening tool for sleep disorders.

**Keywords:** sleep disorder, support vector machine, classification, machine learning, streamlit

## I. PENDAHULUAN

Gangguan tidur merupakan kondisi yang banyak dijumpai dan dapat memengaruhi kesehatan fisik, kondisi psikologis, serta produktivitas seseorang dalam menjalankan aktivitas sehari-hari. Apabila kualitas tidur tidak terpenuhi dengan baik, individu dapat mengalami berbagai dampak negatif seperti rasa lelah, penurunan konsentrasi, hingga meningkatnya risiko gangguan kesehatan apabila terjadi dalam jangka panjang [1], [2]. Jenis gangguan tidur yang umum ditemukan antara lain insomnia, *sleep apnea*, serta gangguan tidur lain yang berhubungan dengan pola dan kualitas tidur seseorang [3], [4].

Terjadinya gangguan tidur tidak terlepas dari berbagai faktor gaya hidup dan kondisi fisiologis. Beberapa faktor seperti durasi tidur, kualitas tidur, tingkat stres, aktivitas fisik, serta tekanan darah memiliki keterkaitan dengan kondisi tidur seseorang [5], [6], [7]. Faktor-faktor tersebut dapat menjadi indikator awal dalam menggambarkan kondisi kesehatan yang berkaitan dengan kualitas tidur. Oleh karena itu, proses deteksi dini terhadap gangguan tidur diperlukan agar seseorang dapat memahami kondisi tidurnya lebih awal dan melakukan langkah pencegahan yang tepat.

Perkembangan teknologi informasi turut mendorong pemanfaatan metode *machine learning* dalam bidang kesehatan. Metode ini banyak digunakan untuk membantu proses pengolahan data, analisis pola, serta klasifikasi kondisi kesehatan secara lebih cepat dan terukur [8], [9], [10]. Salah satu algoritma klasifikasi yang banyak digunakan adalah *Support Vector Machine (SVM)*. Algoritma ini bekerja dengan membentuk *hyperplane* untuk memisahkan data ke dalam beberapa kelas, sehingga mampu menghasilkan performa klasifikasi yang baik pada berbagai jenis data [11], [12].

Sejumlah penelitian terdahulu telah menerapkan metode *machine learning* untuk mengklasifikasikan gangguan tidur. Penelitian dengan metode *Logistic Regression* menunjukkan bahwa data gaya hidup dapat dimanfaatkan untuk mengelompokkan kualitas tidur ke dalam kategori tertentu dengan tingkat akurasi tertentu [13]. Penelitian lainnya menerapkan metode klasifikasi seperti *Decision Tree* dan *Support Vector Machine* untuk mengidentifikasi gangguan tidur berdasarkan faktor kesehatan dan gaya hidup yang berkaitan dengan kualitas tidur [14].

Namun demikian, sebagian besar penelitian sebelumnya masih terbatas pada tahap eksperimen model klasifikasi dan belum banyak yang mengarah pada implementasi sistem yang dapat digunakan secara langsung oleh pengguna. Selain itu, integrasi antara model klasifikasi gangguan tidur dengan aplikasi berbasis *web* sebagai media interaksi pengguna masih belum banyak dikembangkan [15]. Penelitian ini memberikan kontribusi dengan menggabungkan model klasifikasi *Support Vector Machine (SVM)* dan aplikasi *web* berbasis *Streamlit* untuk mendukung proses prediksi gangguan tidur secara interaktif dan mudah diakses.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menerapkan metode *Support Vector Machine (SVM)* dalam mengklasifikasikan gangguan tidur ke dalam tiga kategori, yaitu normal, insomnia, dan *sleep apnea*. Selain itu, penelitian ini juga bertujuan membangun aplikasi *web* berbasis *Streamlit* yang dapat digunakan untuk melakukan prediksi gangguan tidur secara praktis. Sistem yang dikembangkan diharapkan dapat membantu pengguna melakukan skrining awal terhadap kondisi gangguan tidur berdasarkan data gaya hidup dan kondisi fisiologis.

Oleh karena itu, kebaruan (*novelty*) dari penelitian ini terletak pada integrasi *end-to-end* antara model klasifikasi *Support Vector Machine (SVM)* berbasis kernel *polynomial* dengan aplikasi *web* interaktif berbasis *Streamlit*. Integrasi tersebut memungkinkan proses prediksi gangguan tidur dilakukan secara otomatis, mudah diakses, serta dilengkapi dengan tampilan hasil klasifikasi yang dapat dipahami oleh pengguna.

## II. METODE PENELITIAN

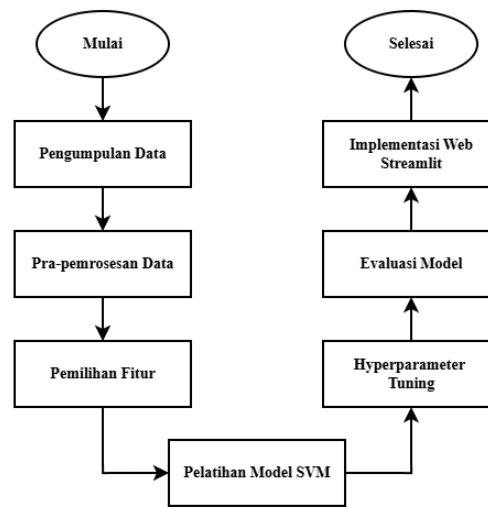
Penelitian ini dilakukan melalui beberapa tahapan yang disusun secara sistematis, mulai dari proses pengumpulan data, pengolahan data, pembangunan model klasifikasi, evaluasi model, hingga implementasi ke dalam aplikasi berbasis *web*. Tahapan penelitian mencakup penggunaan dataset, proses pra-pemrosesan, pelatihan model menggunakan metode *Support Vector Machine (SVM)* serta lima algoritma pembandingan, kemudian dilanjutkan dengan proses *hyperparameter tuning* untuk memperoleh konfigurasi model terbaik. Model dengan performa terbaik selanjutnya dievaluasi dan diterapkan pada aplikasi *web* berbasis *Streamlit* agar dapat digunakan untuk melakukan prediksi gangguan tidur secara interaktif. Alur tahapan penelitian ditunjukkan pada Gambar 1.

### A. Pengumpulan Data

Penelitian ini menggunakan dataset *Sleep Health and Lifestyle* yang diperoleh dari platform Kaggle [16]. Dataset tersebut merupakan data sintesis yang dibangun berdasarkan pola data kesehatan dan memuat informasi terkait gaya hidup serta kondisi fisiologis yang berhubungan dengan kualitas tidur. Atribut yang digunakan dalam dataset meliputi usia, durasi tidur, kualitas tidur, tingkat aktivitas fisik, tingkat stres, detak jantung, jumlah langkah harian (*daily steps*), tekanan darah sistolik, dan tekanan darah diastolik.

Data pada penelitian ini digunakan untuk mengelompokkan kondisi gangguan tidur ke dalam tiga kelas, yaitu normal, insomnia, dan *sleep apnea*. Dataset dipilih karena memiliki atribut yang relevan dengan

faktor-faktor yang berkaitan dengan kualitas tidur, serta telah digunakan dalam penelitian sebelumnya yang membahas analisis kesehatan berbasis *machine learning* [2].



Gambar 1. Tahapan penelitian

## B. Pra Pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk memastikan data siap digunakan dalam proses pelatihan model. Pada tahap ini, data diperiksa dan dibersihkan melalui proses *data cleaning* guna menjaga kualitas data. Selanjutnya, data kategorikal diubah ke dalam bentuk numerik menggunakan teknik *label encoding* agar dapat diproses oleh algoritma *machine learning*.

Selain itu, dilakukan normalisasi menggunakan metode *StandardScaler* untuk menyamakan skala antar fitur. Proses ini diperlukan agar setiap fitur berada pada rentang skala yang sebanding, sehingga dapat membantu meningkatkan performa model *Support Vector Machine (SVM)* dalam melakukan klasifikasi [17].

## C. Pemilihan Fitur

Pemilihan fitur dilakukan untuk menentukan atribut yang digunakan sebagai variabel input dalam proses pelatihan model. Fitur yang dipilih merupakan atribut yang memiliki keterkaitan dengan kualitas tidur dan kondisi fisiologis, sehingga diharapkan dapat mendukung model dalam mengenali pola gangguan tidur secara lebih optimal.

## D. Pelatihan Model SVM dan Algoritma Pembandingan

Pada tahap pelatihan, beberapa algoritma klasifikasi digunakan untuk membandingkan performa model. Algoritma yang digunakan meliputi *Logistic Regression*, *Random Forest*, *Gradient Boosting*, *XGBoost*, *K-Nearest Neighbors (KNN)*, dan *Support Vector Machine (SVM)*. Setiap model dilatih menggunakan data latih yang telah melalui proses pra-pemrosesan dan normalisasi. Evaluasi awal kemudian dilakukan untuk membandingkan performa masing-masing model berdasarkan metrik *accuracy*, *precision*, *recall*, dan *F1-score*.

## E. Proses Hyperparameter Tuning

Proses *hyperparameter tuning* dilakukan untuk memperoleh kombinasi parameter terbaik pada setiap model. Teknik yang digunakan adalah *GridSearchCV* dengan metode *cross-validation*, sehingga setiap kombinasi parameter dapat diuji secara sistematis [18]. Hasil dari proses ini digunakan untuk menentukan konfigurasi model yang menghasilkan performa klasifikasi paling optimal.

## F. Evaluasi Model

Model yang telah dilatih dan dituning kemudian dievaluasi untuk mengetahui kemampuan klasifikasinya. Evaluasi dilakukan menggunakan metrik *accuracy* dan *F1-score*, sehingga performa model dapat dinilai tidak hanya berdasarkan ketepatan prediksi secara keseluruhan, tetapi juga berdasarkan

keseimbangan hasil klasifikasi pada setiap kelas gangguan tidur.

### G. Implementasi Web Streamlit

Tahap terakhir adalah mengimplementasikan model terbaik ke dalam aplikasi *web* berbasis *Streamlit*. Aplikasi ini memungkinkan pengguna memasukkan data gaya hidup dan kondisi fisiologis, seperti durasi tidur, aktivitas fisik, tingkat stres, detak jantung, serta tekanan darah. Data yang dimasukkan kemudian diproses oleh model *SVM* untuk menghasilkan prediksi gangguan tidur beserta nilai probabilitas klasifikasi secara *real-time*.

## III. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil penelitian berdasarkan tahapan yang telah dijelaskan pada metode penelitian. Hasil yang disajikan meliputi proses pra-pemrosesan data, pelatihan model, proses *hyperparameter tuning*, evaluasi dan pemilihan model terbaik, serta implementasi model ke dalam aplikasi *web* berbasis *Streamlit*. Pembahasan juga dilakukan untuk menjelaskan kinerja model dalam mengklasifikasikan gangguan tidur serta membandingkan hasil yang diperoleh dengan penelitian sebelumnya.

### A. Hasil Pra Pemrosesan Data

Dataset yang digunakan pada penelitian ini merupakan dataset sintesis yang dibangun berdasarkan pola data kesehatan. Oleh karena itu, fokus utama penelitian diarahkan pada pengujian kemampuan model dalam melakukan klasifikasi berdasarkan pola data yang tersedia. Berdasarkan hasil pemeriksaan data, tidak ditemukan nilai kosong (*missing value*) pada dataset, sehingga proses imputasi tidak perlu dilakukan.

Tahap berikutnya adalah menentukan fitur yang digunakan sebagai variabel input model. Fitur yang dipilih meliputi usia, durasi tidur, kualitas tidur, tingkat aktivitas fisik, tingkat stres, detak jantung, jumlah langkah harian, tekanan darah sistolik, dan tekanan darah diastolik. Pemilihan fitur tersebut didasarkan pada keterkaitannya dengan kualitas tidur dan kondisi fisiologis seseorang.

Data kategorikal kemudian diubah menjadi bentuk numerik menggunakan teknik *label encoding* agar dapat diproses oleh algoritma *machine learning*. Setelah itu, dilakukan analisis distribusi kelas pada variabel target untuk mengetahui jumlah data pada masing-masing kategori gangguan tidur.

**Tabel 1.** Distribusi kelas pada dataset.

| <b>Insomnia</b> | <b>Sleep Apnea</b> | <b>Normal</b> |
|-----------------|--------------------|---------------|
| 77              | 78                 | 219           |

Berdasarkan Tabel 1, dataset terdiri dari tiga kelas, yaitu Normal sebanyak 219 data, Insomnia sebanyak 77 data, dan Sleep Apnea sebanyak 78 data. Distribusi tersebut menunjukkan adanya dominasi pada kelas Normal dibandingkan dua kelas lainnya. Meskipun demikian, ketidakseimbangan tersebut masih dapat ditoleransi oleh model *SVM*. Untuk menjaga objektivitas evaluasi pada setiap kelas, penelitian ini menggunakan metrik *F1-score* makro tanpa menerapkan teknik *oversampling*.

Selain itu, seluruh fitur numerik dinormalisasi menggunakan metode *StandardScaler*. Normalisasi dilakukan agar setiap fitur berada pada skala yang sebanding, sehingga proses pembelajaran model dapat berjalan lebih optimal, terutama pada algoritma yang sensitif terhadap skala data seperti *SVM*.

### B. Pelatihan Model

Dataset dibagi menjadi dua bagian, yaitu data latih dan data uji dengan rasio 80:20 menggunakan metode *train-test split*. Parameter *stratify* digunakan untuk mempertahankan proporsi kelas pada data latih dan data uji agar distribusi target tetap terwakili dengan baik.

Pada tahap pelatihan, penelitian ini menggunakan enam algoritma klasifikasi, yaitu *Logistic Regression*, *Random Forest*, *Gradient Boosting*, *XGBoost*, *K-Nearest Neighbors (KNN)*, dan *Support Vector Machine (SVM)*. Seluruh model dilatih menggunakan data yang telah melalui tahap pra-pemrosesan dan normalisasi.

Evaluasi awal dilakukan untuk mengetahui performa masing-masing model sebelum proses *hyperparameter tuning*. Metrik yang digunakan meliputi *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil evaluasi awal ditampilkan pada Tabel 2.

**Tabel 2.** Perbandingan performa model.

| Model               | Accuracy | Precision (Macro) | Recall (Macro) | F1-Score (Macro) | Cross-Val Score (Mean) | Cross-Val Score (Std) |
|---------------------|----------|-------------------|----------------|------------------|------------------------|-----------------------|
| Random Forest       | 0,9600   | 0,9370            | 0,9347         | 0,9352           | 0,8795                 | 0,0248                |
| K-Nearest Neighbors | 0,9600   | 0,9370            | 0,9347         | 0,9352           | 0,8829                 | 0,0215                |
| SVM                 | 0,9600   | 0,9474            | 0,9333         | 0,9344           | 0,8895                 | 0,0176                |
| XGBoost             | 0,9333   | 0,8931            | 0,8931         | 0,8925           | 0,8629                 | 0,0338                |
| Gradient Boosting   | 0,9333   | 0,8931            | 0,8931         | 0,8925           | 0,8863                 | 0,0195                |
| Logistic Regression | 0,9067   | 0,8578            | 0,8765         | 0,8665           | 0,8997                 | 0,0183                |

Berdasarkan Tabel 2, model *Random Forest* memperoleh nilai *accuracy* sebesar 96% dan *F1-score* makro sebesar 0,9352. Nilai tersebut menunjukkan bahwa *Random Forest* menjadi model dengan performa awal terbaik sebelum proses optimasi. Namun, karena beberapa model lain seperti *KNN* dan *SVM* juga menunjukkan performa yang kompetitif, seluruh model tetap dilanjutkan ke tahap *hyperparameter tuning* untuk memperoleh konfigurasi parameter yang lebih optimal.

### C. Hyperparameter Tuning

Proses *hyperparameter tuning* dilakukan untuk mencari kombinasi parameter terbaik dari setiap model yang digunakan. Teknik yang diterapkan adalah *GridSearchCV*, yaitu metode pencarian parameter secara sistematis berdasarkan kombinasi nilai yang telah ditentukan. Pada penelitian ini, proses validasi dilakukan menggunakan *5-fold cross-validation* untuk memperoleh hasil evaluasi yang lebih stabil dan mengurangi risiko *overfitting*.

**Tabel 3.** Hasil hyperparameter tuning.

| Model               | Parameter Terbaik   | Cross-Val Score |
|---------------------|---|-----------------|
| Random Forest       | <i>max_depth=10, min_samples_leaf=2, min_samples_split=10, n_estimators=200</i> | 0,8732          |
| K-Nearest Neighbors | <i>metric=manhattan, n_neighbors=7, weights=uniform</i>                         | 0,8554          |
| SVM                 | <i>C=1, gamma=scale, kernel=poly</i>  | 0,8786          |
| XGBoost             | <i>learning_rate=0.1, max_depth=3, n_estimators=100, subsample=0.8</i>          | 0,8775          |
| Gradient Boosting   | <i>learning_rate=0.01, max_depth=5, min_samples_split=10, n_estimators=200</i>  | 0,8734          |
| Logistic Regression | <i>C=1, penalty=l2, solver=lbfgs</i>  | 0,8733          |

Berdasarkan Tabel 3, seluruh model telah melalui proses *hyperparameter tuning*. Hasil terbaik diperoleh oleh model *SVM* dengan kombinasi parameter *C=1, gamma=scale, dan kernel=poly*, serta menghasilkan nilai *cross-validation score* sebesar 0,8786. Hasil ini menunjukkan bahwa konfigurasi tersebut mampu memberikan performa validasi terbaik dibandingkan model lain pada tahap tuning. Selanjutnya, seluruh model hasil tuning dievaluasi kembali untuk menentukan model yang paling tepat digunakan pada aplikasi *web*.

### D. Evaluasi dan Pemilihan Model

Evaluasi model dilakukan untuk mengetahui kemampuan masing-masing algoritma dalam mengklasifikasikan gangguan tidur. Penilaian dilakukan menggunakan metrik *accuracy, precision, recall, dan F1-score*. Selain itu, nilai *cross-validation* juga digunakan untuk melihat kestabilan performa model pada beberapa pembagian data.

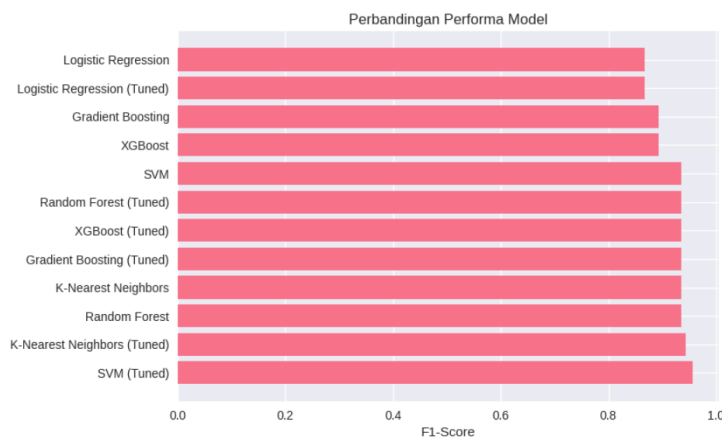
Berdasarkan Tabel 2, model *Random Forest, K-Nearest Neighbors (KNN), dan Support Vector Machine (SVM)* menunjukkan performa awal yang cukup baik. Sebelum tuning, *Random Forest* dan *KNN* memperoleh nilai *F1-score* yang sedikit lebih tinggi, sedangkan *SVM* menunjukkan performa yang masih kompetitif.

Setelah dilakukan proses *hyperparameter tuning*, beberapa model mengalami peningkatan performa. Peningkatan paling menonjol terlihat pada model *SVM*, sebagaimana ditampilkan pada Tabel 4.

**Tabel 4.** Hasil evaluasi seluruh model.

| Model                       | Accuracy | Precision (Macro) | Recall (Macro) | F1-Score (Macro) | Cross-Val Score (Mean) | Cross-Val Score (Std) |
|-----------------------------|----------|-------------------|----------------|------------------|------------------------|-----------------------|
| SVM (Tuned)                 | 0,9733   | 0,9569            | 0,9569         | 0,9569           | 0,8786                 | 0,0468                |
| KNN (Tuned)                 | 0,9600   | 0,9375            | 0,9494         | 0,9431           | 0,8554                 | 0,0581                |
| Random Forest               | 0,9600   | 0,9370            | 0,9347         | 0,9352           | 0,8795                 | 0,0248                |
| KNN                         | 0,9600   | 0,9370            | 0,9347         | 0,9352           | 0,8829                 | 0,0215                |
| Gradient Boosting (Tuned)   | 0,9600   | 0,9370            | 0,9347         | 0,9352           | 0,8734                 | 0,0435                |
| XGBoost (Tuned)             | 0,9600   | 0,9370            | 0,9347         | 0,9352           | 0,8775                 | 0,0360                |
| Random Forest (Tuned)       | 0,9600   | 0,9474            | 0,9333         | 0,9344           | 0,8732                 | 0,0384                |
| SVM                         | 0,9600   | 0,9474            | 0,9333         | 0,9344           | 0,8995                 | 0,0176                |
| XGBoost                     | 0,9333   | 0,8931            | 0,8931         | 0,8925           | 0,8629                 | 0,0338                |
| Gradient Boosting           | 0,9333   | 0,8931            | 0,8931         | 0,8925           | 0,8863                 | 0,0195                |
| Logistic Regression (Tuned) | 0,9067   | 0,8578            | 0,8765         | 0,8665           | 0,8733                 | 0,0522                |
| Logistic Regression         | 0,9067   | 0,8578            | 0,8765         | 0,8665           | 0,8997                 | 0,0183                |

Berdasarkan Tabel 4, model *KNN (Tuned)*, *XGBoost (Tuned)*, dan *Gradient Boosting (Tuned)* juga menghasilkan performa yang tinggi. Namun, model *SVM (Tuned)* memperoleh hasil terbaik dengan nilai akurasi sebesar 97,33% dan *F1-score* makro sebesar 0,9569. Nilai tersebut menunjukkan bahwa model mampu melakukan klasifikasi secara lebih seimbang pada setiap kelas. Selain itu, hasil *cross-validation* menunjukkan bahwa model memiliki performa yang stabil dan mampu melakukan generalisasi dengan baik.




**Gambar 2.** Visualisasi perbandingan model.

Gambar 2 memperlihatkan perbandingan nilai *F1-score* antar model. Berdasarkan visualisasi tersebut, *SVM (Tuned)* menjadi model dengan performa tertinggi dibandingkan model lainnya.



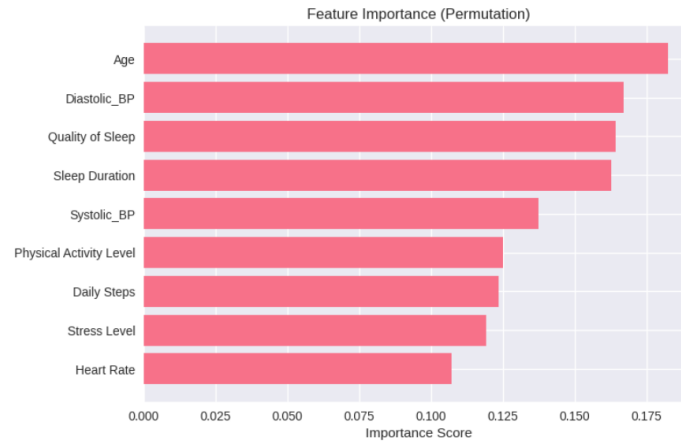
**Gambar 3.** Visualisasi perbandingan model sebelum dan sesudah tuning.

Gambar 3 menunjukkan adanya perubahan performa sebelum dan sesudah proses *hyperparameter tuning*. Peningkatan paling terlihat terjadi pada model *SVM*, sehingga proses tuning terbukti berperan dalam meningkatkan performa klasifikasi.



**Gambar 4.** Confusion Matrix SVM (Tuned).

Berdasarkan Gambar 4, model *SVM (Tuned)* mampu mengklasifikasikan sebagian besar data uji dengan benar. Kesalahan klasifikasi yang muncul relatif kecil, sehingga model dapat dikatakan memiliki performa yang baik dalam membedakan kelas Normal, Insomnia, dan *Sleep Apnea*.



**Gambar 5.** Visualisasi Fitur Paling Berpengaruh.

Berdasarkan Gambar 5, analisis *feature importance* menggunakan metode *permutation importance*, fitur yang paling berpengaruh terhadap hasil prediksi adalah Age, Diastolic\_BP, dan Quality of Sleep. Metode *permutation importance* digunakan karena mampu mengukur dampak penurunan performa model ketika suatu fitur diacak, sehingga interpretasi yang dihasilkan lebih merepresentasikan kontribusi fitur terhadap model. Pada penelitian ini, hasil *permutation importance* dianggap lebih relevan dibandingkan *SHAP* karena penilaian dilakukan berdasarkan perubahan performa model secara langsung.

Pemilihan model terbaik dalam penelitian ini didasarkan pada metrik *accuracy* dan *F1-score* makro. *Accuracy* digunakan untuk melihat ketepatan prediksi secara keseluruhan, sedangkan *F1-score* makro digunakan untuk menilai keseimbangan performa antar kelas. Penggunaan *F1-score* makro menjadi penting karena penelitian ini menggunakan klasifikasi multi-kelas. Berdasarkan hasil evaluasi dan visualisasi, model *Support Vector Machine (SVM)* setelah proses *hyperparameter tuning* dipilih sebagai model terbaik. Pemilihan parameter yang tepat mampu meningkatkan kemampuan model dalam membentuk batas keputusan yang lebih optimal sehingga hasil klasifikasi menjadi lebih akurat.

Hasil penelitian ini menunjukkan bahwa model *Support Vector Machine (SVM)* dengan *hyperparameter tuning* memperoleh akurasi sebesar 97,33% dan *F1-score* makro sebesar 0,9569. Nilai tersebut lebih tinggi dibandingkan penelitian [13] yang menggunakan metode *Logistic Regression* dengan akurasi sebesar 77%. Selain itu, hasil penelitian ini juga lebih baik dibandingkan penelitian [14] yang menggunakan metode *Decision Tree* dengan akurasi sebesar 89%. Perbedaan performa tersebut dapat dipengaruhi oleh penggunaan normalisasi data dengan *StandardScaler*, proses *hyperparameter tuning*, serta penerapan kernel *polynomial (poly)* pada model *SVM* yang mampu menangkap pola data non-linear secara lebih optimal.

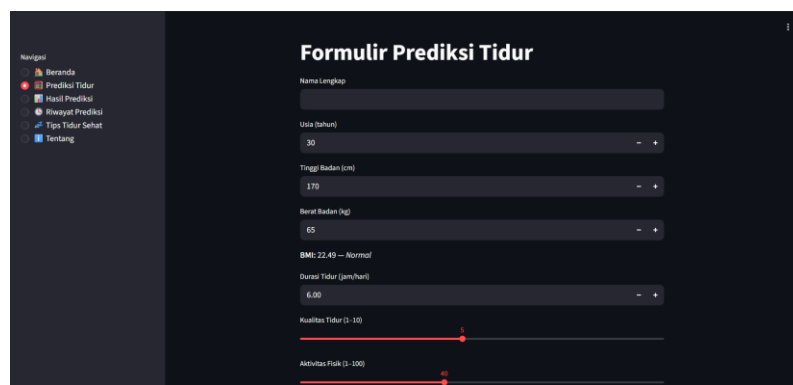
### E. Implementasi Sistem

Model terbaik yang diperoleh dari tahap evaluasi kemudian diimplementasikan ke dalam aplikasi *web* berbasis *Streamlit*. Implementasi ini dilakukan agar model tidak hanya digunakan pada tahap eksperimen, tetapi juga dapat dimanfaatkan dalam bentuk sistem interaktif untuk membantu pengguna melakukan prediksi gangguan tidur.



Gambar 6. Halaman Beranda Sistem.

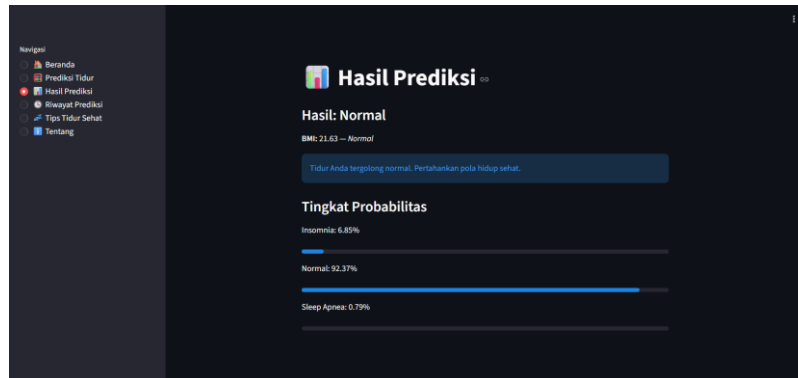
Aplikasi yang dikembangkan terdiri dari beberapa halaman utama, yaitu halaman beranda (Gambar 6), halaman formulir prediksi (Gambar 7), halaman hasil prediksi (Gambar 8), riwayat prediksi, dan halaman tips tidur sehat. Halaman beranda berfungsi sebagai tampilan awal yang memberikan gambaran umum mengenai sistem, sedangkan halaman formulir digunakan untuk memasukkan data yang diperlukan dalam proses prediksi.



Gambar 7. Form Input Data Prediksi.

Data yang dimasukkan ke dalam sistem meliputi usia, durasi tidur, kualitas tidur, aktivitas fisik, tingkat stres, detak jantung, jumlah langkah harian, tekanan darah sistolik, dan tekanan darah diastolik. Selain itu, sistem juga menghitung nilai *Body Mass Index (BMI)* berdasarkan tinggi dan berat badan pengguna. Nilai BMI tersebut ditampilkan sebagai informasi tambahan dan tidak digunakan sebagai fitur utama model karena dataset pelatihan tidak memuat fitur BMI numerik.

Data input pengguna diproses melalui normalisasi menggunakan *StandardScaler*, sesuai dengan tahapan yang diterapkan pada proses pelatihan. Setelah itu, data yang telah dinormalisasi digunakan sebagai input pada model *Support Vector Machine (SVM)* yang telah melalui proses *hyperparameter tuning*.



**Gambar 8.** Tampilan Hasil Prediksi.

Hasil keluaran sistem berupa klasifikasi gangguan tidur ke dalam tiga kategori, yaitu Normal, Insomnia, dan *Sleep Apnea*. Sistem juga menampilkan probabilitas dari setiap kelas untuk memberikan informasi mengenai tingkat keyakinan model terhadap hasil prediksi.

Aplikasi ini dilengkapi fitur riwayat prediksi sementara agar pengguna dapat melihat kembali hasil prediksi yang telah dilakukan. Selain itu, sistem memberikan keterangan dan rekomendasi singkat berdasarkan hasil klasifikasi, sehingga pengguna dapat memperoleh informasi awal mengenai kondisi tidur yang diprediksi.

Dengan adanya implementasi ini, model klasifikasi yang dikembangkan dapat diterapkan dalam bentuk aplikasi praktis. Sistem ini diharapkan dapat menjadi alat bantu skrining awal gangguan tidur yang interaktif dan mudah digunakan.

## F. Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa aplikasi *web* yang dikembangkan dapat berfungsi sesuai tujuan. Pengujian dilakukan dengan memasukkan beberapa data uji ke dalam sistem seperti data pada Tabel 5, kemudian hasil prediksi dibandingkan dengan label asli pada dataset.

Data uji yang digunakan merupakan sampel dari dataset *Sleep Health and Lifestyle* yang mewakili tiga kelas gangguan tidur, yaitu Normal, Insomnia, dan *Sleep Apnea*. Parameter yang digunakan dalam pengujian meliputi usia, durasi tidur, kualitas tidur, aktivitas fisik, tingkat stres, detak jantung, jumlah langkah harian, serta tekanan darah sistolik dan diastolik.

**Tabel 5.** Pengujian Input Data Uji.

| No | Usia | Durasi Tidur (jam/hari) | Kualitas Tidur | Aktivitas Fisik (menit/hari) | Tingkat Stress | Detak Jantung | Langkah Harian | Tekanan Darah |
|----|------|-------------------------|----------------|------------------------------|----------------|---------------|----------------|---------------|
| 1  | 45   | 6.5                     | 7              | 45                           | 4              | 65            | 6000           | 135/90        |
| 2  | 44   | 6.5                     | 7              | 45                           | 4              | 65            | 6000           | 135/90        |
| 3  | 31   | 7.7                     | 7              | 75                           | 6              | 70            | 8000           | 120/80        |
| 4  | 38   | 7.1                     | 8              | 60                           | 4              | 68            | 7000           | 115/75        |
| 5  | 50   | 6.0                     | 6              | 90                           | 8              | 75            | 10000          | 140/95        |
| 6  | 59   | 8.1                     | 9              | 75                           | 3              | 68            | 7000           | 140/95        |
| 7  | 28   | 7.5                     | 8              | 70                           | 3              | 68            | 9000           | 118/78        |
| 8  | 35   | 5.5                     | 4              | 30                           | 8              | 78            | 4000           | 130/85        |
| 9  | 52   | 6.2                     | 5              | 70                           | 7              | 85            | 8000           | 145/95        |

**Tabel 6.** Hasil Pengujian Sistem.

| No | Hasil Sistem | Label Asli | Status |
|----|--------------|------------|--------|
| 1  | Insomnia     | Insomnia   | Sesuai |
| 2  | Insomnia     | Insomnia   | Sesuai |
| 3  | Normal       | Normal     | Sesuai |
| 4  | Normal       | Normal     | Sesuai |

| No | Hasil Sistem | Label Asli  | Status |
|----|--------------|-------------|--------|
| 5  | Sleep Apnea  | Sleep Apnea | Sesuai |
| 6  | Sleep Apnea  | Sleep Apnea | Sesuai |
| 7  | Normal       | Normal      | Sesuai |
| 8  | Insomnia     | Insomnia    | Sesuai |
| 9  | Sleep Apnea  | Sleep Apnea | Sesuai |

Berdasarkan Tabel 6, sebagian besar data uji menghasilkan prediksi yang sesuai dengan label asli. Hasil ini menunjukkan bahwa model yang diimplementasikan pada aplikasi *web* mampu memberikan prediksi yang konsisten terhadap data uji yang memiliki karakteristik serupa dengan data pelatihan.

#### IV. KESIMPULAN

Penelitian ini dilakukan untuk membangun model klasifikasi gangguan tidur berbasis *machine learning* dengan memanfaatkan data gaya hidup dan kondisi fisiologis. Berdasarkan hasil pengujian, model *Support Vector Machine (SVM)* yang telah melalui proses *hyperparameter tuning* memperoleh performa terbaik dibandingkan algoritma pembandingan lainnya dalam mengklasifikasikan gangguan tidur.

Model *SVM (Tuned)* menghasilkan akurasi sebesar 97,33% dan nilai *F1-score* makro sebesar 0,9569. Hasil tersebut menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik serta mampu menjaga keseimbangan performa pada setiap kelas. Proses *hyperparameter tuning* juga terbukti mampu meningkatkan performa model dibandingkan sebelum dilakukan optimasi parameter.

Hasil analisis *feature importance* menggunakan metode *permutation importance* menunjukkan bahwa fitur Age, Diastolic Blood Pressure, dan Quality of Sleep menjadi fitur yang paling berpengaruh terhadap prediksi model. Temuan ini mengindikasikan bahwa faktor usia, tekanan darah diastolik, dan kualitas tidur memiliki kontribusi penting dalam proses klasifikasi gangguan tidur.

Model terbaik kemudian diimplementasikan ke dalam aplikasi *web* berbasis *Streamlit* agar dapat digunakan secara interaktif oleh pengguna. Berdasarkan hasil pengujian sistem, aplikasi mampu berjalan dengan baik dan memberikan hasil prediksi yang konsisten terhadap data uji yang diberikan.

Penelitian ini masih memiliki keterbatasan karena dataset yang digunakan merupakan dataset sintetis, sehingga pola data belum sepenuhnya merepresentasikan kondisi nyata. Oleh karena itu, penelitian selanjutnya disarankan menggunakan *real dataset* agar hasil model lebih sesuai dengan kondisi sebenarnya. Pengembangan berikutnya juga dapat menambahkan fitur lain seperti *Body Mass Index (BMI)*, kebiasaan tidur, konsumsi kafein, serta durasi penggunaan perangkat elektronik sebelum tidur untuk meningkatkan kelengkapan data input.

Selain itu, penelitian lanjutan dapat menguji metode lain seperti *deep learning* atau metode *ensemble* untuk memperoleh perbandingan performa yang lebih luas. Dari sisi implementasi, sistem dapat dikembangkan dengan integrasi perangkat *wearable* atau *smartwatch* agar data pengguna dapat diperoleh secara *real-time*. Aplikasi juga dapat ditingkatkan dengan fitur penyimpanan data permanen, riwayat pengguna, dan rekomendasi kesehatan yang lebih personal sehingga sistem tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai media pendukung peningkatan kualitas tidur pengguna.

#### DAFTAR PUSTAKA

- [1] D. M. Siregar and C. A. Rengkuhan, "Analisis Faktor-Faktor yang Berperan dalam Kualitas Tidur pada Mahasiswa Tingkat Akhir," *OBAT: Jurnal Riset Ilmu Farmasi dan Kesehatan*, vol. 3, no. 1, pp. 01–14, 2025, doi: 10.61132/obat.v3i1.893.
- [2] D. S. M. Jannah and H. G. Hidajat, "Analisis Faktor Penyebab dari Gangguan Tidur: Kajian Psikologi Lintas Budaya," *Psyche 165 Journal*, pp. 164–171, Jul. 2024, doi: 10.35134/jpsy165.v17i3.372.
- [3] N. Nuraeni and M. Faisal, "Classification of Sleep Disorders using Support Vector Machine," *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, Feb. 2025, doi: 10.22219/kinetik.v10i1.2054.
- [4] D. A. P. D. I. Pradhani, M. O. A. Kamayani, I. K. Saputra, and M. V. Manangkot, "Hubungan Resiliensi dengan Kualitas Tidur Pasien di Ruang Rawat Inap RSUD Wangaya Kota Denpasar," *Community of Publishing in Nursing*, vol. 13, no. 2, pp. 145–152, Apr. 2025, doi: 10.24843/coping.2025.v13.i02.p04.

- 
- [5] H. Mufidah, M. A. Maulana, Y. Pramana, G. N. Rahmah, and M. Mita, "Stres Akademik Sebagai Determinan Kualitas Tidur Remaja di Madrasah Aliyah," *Jurnal Penelitian Kesehatan "SUARA FORIKES" (Journal of Health Research "Forikes Voice")*, vol. 15, no. 4, pp. 695–698, Nov. 2024, doi: 10.33846/sf15425.
- [6] R. J. Utami, R. Indarwati, and R. Pradanie, "Analisa Faktor Yang Mempengaruhi Kualitas Tidur Lansia Di Panti," *Jurnal Health Sains*, vol. 2, no. 3, pp. 362–380, Mar. 2021, doi: 10.46799/jhs.v2i3.135.
- [7] S. Muntomimah and S. Mubarak, "Analisis Faktor-Faktor yang Mempengaruhi Kualitas Tidur pada Remaja berskala Biner," *Efektor*, vol. 12, no. 1, pp. 63–74, Apr. 2025, doi: 10.29407/e.v12i1.24850.
- [8] D. Fitriyani, M. Amelia, and S. S. Yuliana, "Penerapan Algoritma Random Forest Untuk Klasifikasi Gangguan Tidur Berdasarkan Pola Kehidupan Sehari-hari," *Jurnal Aplikasi Informatika dan Multimedia*, vol. 1, no. 1, pp. 21–26, Jul. 2025, doi: 10.64878/japtika.v1i1.82.
- [9] R. G. Wardhana, G. Wang, and F. Sibuea, "Penerapan Machine Learning dalam Prediksi Tingkat Kasus Penyakit di Indonesia," *Journal of Information System Management (JOISM)*, vol. 5, no. 1, pp. 40–45, Jul. 2023, doi: 10.24076/joism.2023v5i1.1136.
- [10] I. Akbar, F. Supriadi, and D. I. Junaedi, "Pemanfaatan Machine Learning di Bidang Kesehatan," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 1, pp. 1744–1749, Dec. 2024, doi: 10.36040/jati.v9i1.12663.
- [11] H. S. W. Hovi, A. I. Hadiana, and F. R. Umbara, "Prediksi Penyakit Diabetes Menggunakan Algoritma Support Vector Machine (SVM)," *Informatics and Digital Expert (INDEX)*, vol. 4, no. 1, pp. 40–45, 2022, doi: 10.36423/index.v4i1.895.
- [12] F. Abdusyukur, "Penerapan Algoritma Support Vector Machine (SVM) untuk Klasifikasi Pencemaran Nama Baik di Media Sosial Twitter," *KOMPUTA*, vol. 12, no. 1, pp. 73–82, May 2023, doi: 10.34010/komputa.v12i1.9418.
- [13] R. Nugraha et al., "Pengembangan Website Klasifikasi Kualitas Tidur dan Rekomendasi Penanganan Menggunakan Logistic Regression," *RISTEK : Jurnal Riset, Inovasi dan Teknologi Kabupaten Batang*, vol. 9, no. 2, pp. 30–36, Jun. 2025, doi: 10.55686/ristek.v9i2.204.
- [14] F. Andriani, N. Rahmania, and N. Alfiana, "Identifikasi Gangguan Tidur Menggunakan Klasifikasi Berbasis Decision Tree," *1*, vol. 2, no. 2, pp. 85–93, Aug. 2025, doi: 10.34304/scientific.v2i2.394.
- [15] T. K. Amarya, R. Firliana, and A. Ristyawan, "Aplikasi Deteksi Dini Penyakit Stroke Menggunakan Streamlit," *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 9, no. 1, pp. 453–462, Jul. 2025, doi: 10.29407/xgvr9h34.
- [16] L. Tharmalingam, "Sleep Health and Lifestyle Dataset," Kaggle. Accessed: Oct. 11, 2025. [Online]. Available: <https://www.kaggle.com/datasets/uom190346a/sleep-health-and-lifestyle-dataset>
- [17] M. Darip, A. Sapaatullah, and R. Rahmat, "Implementasi Support Vector Machine (SVM) Untuk Deteksi Serangan Jaringan Pada Sistem Keamanan Jaringan Kampus.," *Bulletin of Information Technology (BIT)*, vol. 7, no. 1, pp. 40–49, Mar. 2026, doi: 10.47065/bit.v7i1.2602.
- [18] Z. M. E. Darmawan and A. F. Dianta, "Implementasi Optimasi Hyperparameter GridSearchCV Pada Sistem Prediksi Serangan Jantung Menggunakan SVM," *Teknologi: Jurnal Ilmiah Sistem Informasi*, vol. 13, no. 1, pp. 8–15, Jan. 2023, doi: 10.26594/teknologi.v13i1.3098.
-