

Terbit online pada laman : <http://teknosi.fti.unand.ac.id/>

Jurnal Nasional Teknologi dan Sistem Informasi

| ISSN (Print) 2460-3465 | ISSN (Online) 2476-8812 |



Artikel Penelitian

Deteksi Kelelahan Pengendara Sepeda Motor Secara Multimodal Menggunakan Sinyal Denyut Nadi dan Postur Tubuh Berbasis Support Vector Machine

Dody Ichwana Putra ^{a,*}, Alvira Adira ^b, Shelvi Ekariani ^c

^{a,b} Departemen Teknik Komputer, Universitas Andalas, Kota Padang 25163, Indonesia

^c Departemen Matematika dan Data Sains, Universitas Andalas, Kota Padang 25163, Indonesia

INFORMASI ARTIKEL

Sejarah Artikel:

Diterima Redaksi: 03 Juli 2025

Revisi Akhir: 02 September 2025

Diterbitkan Online: 12 Mei 2026

KATA KUNCI

Deteksi kelelahan, pengendara sepeda motor, denyut nadi, postur tubuh, Support Vector Machine

KORESPONDENSI

E-mail: dody.ichwana@it.unand.ac.id *

A B S T R A C T

Kelelahan pengendara sepeda motor merupakan salah satu faktor utama yang berkontribusi terhadap meningkatnya risiko kecelakaan lalu lintas. Penelitian ini mengusulkan sebuah sistem deteksi kelelahan pengendara sepeda motor berbasis multimodal dengan memanfaatkan sinyal denyut nadi dan postur tubuh sebagai indikator kondisi pengendara. Data denyut nadi dan sudut kemiringan tubuh diperoleh melalui perangkat *wearable* dan diproses pada sisi *edge* untuk mengekstraksi fitur-fitur penting. Selanjutnya, fitur multimodal tersebut diklasifikasikan menggunakan algoritma Support Vector Machine (SVM) untuk menentukan kondisi pengendara ke dalam tiga kelas, yaitu normal, mengantuk sedang, dan mengantuk berat. Hasil klasifikasi ditampilkan melalui aplikasi Android dan digunakan sebagai dasar pemberian peringatan kepada pengendara apabila terdeteksi kondisi kelelahan. Hasil pengujian menunjukkan bahwa sistem mampu mengklasifikasikan kondisi pengendara secara tepat dengan tingkat akurasi, presisi, *recall*, dan F1-score yang tinggi pada data pengujian. Sistem yang diusulkan berpotensi digunakan sebagai sistem peringatan dini untuk meningkatkan keselamatan pengendara sepeda motor, khususnya pada perjalanan dengan durasi yang panjang.

1. PENDAHULUAN

Kelelahan pada pengendara sepeda motor merupakan salah satu penyebab kecelakaan lalu lintas. Kondisi lelah dapat menurunkan tingkat kewaspadaan saat berkendara sehingga memperlambat respon saat terjadi gangguan berkendara sehingga meningkatkan risiko dalam berkendara. Dampak kelelahan {Citation} pada pengendara sepeda motor lebih berbahaya karena berpengaruh pada kestabilan saat berkendara disamping perlindungan fisik yang lebih rendah dibanding pengendara mobil [1][2].

Berbagai penelitian telah dilakukan dengan berbagai pendekatan untuk mendeteksi kelelahan dan mengantuk pada pengendara. Pada penelitian dengan pendekatan berbasis visual, seperti kedipan mata dan ekspresi wajah dilaporkan mampu memperoleh hasil akurat untuk mendeteksi kantuk pengendara dalam lingkungan simulasi dan terkontrol. Namun, pendekatan ini mempunyai keterbatasan saat implementasi *real* karena adanya

faktor perubahan cahaya, penggunaan helm, getaran kendaraan atau situasi cuaca seperti hujan dan kabut [4]. Pendekatan lain seperti berbasis sinyal fisiologis untuk mendeteksi kantuk juga dikembangkan karena tidak bergantung pada kondisi lingkungan. Sinyal *heart rate variability* (HRV) mempunyai korelasi yang kuat untuk mendeteksi kelelahan dan kantuk [5][6][7][8]. Pada penelitian [9] menunjukkan algoritma *machine learning*, seperti *support vector machine* (SVM), *random forest* dan *neural network* mempunyai akurasi yang baik untuk mengklasifikasi lelah dan kantuk berbasis fitur HRV. Namun implementasinya untuk pengendara motor pada kondisi *real* masih terbatas [10][11].

Disamping parameter fisiologis, perubahan postur dan gerakan tubuh pengendara juga memperlihatkan ciri kelelahan dan kantuk [12]. Perubahan postur seperti ketidakstabilan posisi duduk, kemiringan tubuh atau penurunan respon motorik dapat menjadi indikator kelelahan dan kantuk pada pengendara motor. Sensor

inertial measurements unit (IMU), seperti gyroscope dan accelerometer telah banyak digunakan untuk mendeteksi perubahan orientasi tubuh serta gerakan tubuh [12]. Namun penggunaan satu jenis pendekatan saja dinilai belum mampu untuk merepresentasikan kondisi lelah dan kantuk, karena lelah dan kantuk bersifat multifaktor yang melibatkan sinyal fisiologis dan kondisi (perilaku) tubuh pengendara secara bersamaan [13].

Pada penelitian [13], penggabungan lebih parameter sinyal fisiologis dan perilaku tubuh pengendara (multimodal) mampu meningkatkan akurasi dan generalisasi deteksi kelelahan dan kantuk dibanding pendekatan unimodal. Integrasi data dari sensor denyut jantung dan sensor IMU pada perangkat *wearable* dinilai lebih sesuai untuk pemantauan jangka panjang secara non-intrusif, terkhususnya pada kondisi yang dinamis seperti pada pengendara motor [14][15].

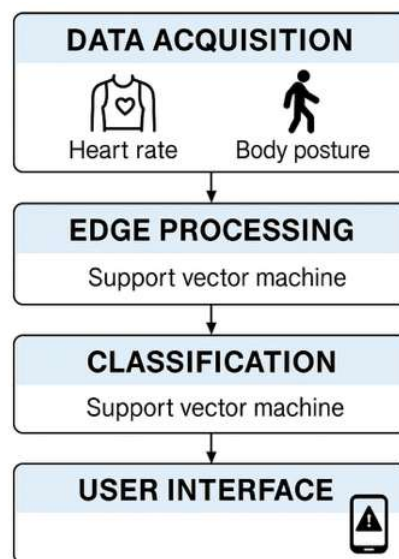
Pada penelitian ini, diusulkan sistem deteksi kelelahan pengendara sepeda motor secara multimodal menggunakan sinyal denyut nadi dan postur tubuh berbasis support vector machine (SVM). Sistem ini dirancang untuk bekerja secara *real-time* dan terintegrasi *internet of things (IoT)* dengan mengintegrasikan sinyal denyut nadi dan orientasi postur tubuh pengendara motor. Kontribusi penelitian ini: (1) penggunaan pendekatan multimodal pada pengendara sepeda motor, (2) integrasi sensor fisiologis dan sensor tubuh dalam perangkat *wearable*, (3) sistem dievaluasi pada skenario *real*.

2. METODE

2.1. Arsitektur Sistem

Sistem ini dirancang dengan pendekatan multimodal berbasis *wearable*. Masukan sistem berupa sinyal denyut nadi dan postur tubuh dari sensor IMU yang dianalisis menggunakan algoritma SVM. Apabila sistem mendeteksi kondisi lelah yang ditandai dengan mengantuk, sistem akan mengaktifkan alarm untuk pengendara. Sistem dirancang terdiri dari lapisan data akuisisi data, lapisan *edge processing* (pemrosesan tepi), lapisan klasifikasi *machine learning*, dan layer *interface* (antarmuka) pengguna, seperti ditunjukkan pada Gambar 1.

Pada lapisan akuisisi, data yang berasal dari sensor yang terpasang pada perangkat *wearable* pengendara di unit rompi (*vest unit*) dan unit gelang (*wrist unit*). Perangkat *wearable* unit-ompi ditanamkan sensor MPU 6050 dan unit-gelang tangan menggunakan sensor pulse. *Raw* data dari sensor MPU 6050 digunakan untuk mendapatkan perubahan orientasi postur tubuh pengendara motor selama berkendara dan sensor pulse untuk mendapatkan denyut nadi. *Raw* data akan diproses pada lapisan-*edge* dengan tahapan pengkondisian sinyal dan filtrasi noise. Selanjutnya, fitur hasil pemrosesan dimasukkan ke dalam model SVM untuk mengklasifikasikan pengendara ke kelas: normal, mengantuk sedang, dan mengantuk berat. Hasil klasifikasi selanjutnya dikirimkan ke aplikasi Android pada lapisan antarmuka untuk pemberian notifikasi peringatan dan penyimpanan riwayat data untuk analisis lanjutan. Arsitektur sistem ini ditunjukkan Gambar 2.



Gambar 1. Lapisan Pemrosesan Data

2.2. Featuring Engineering

Raw data yang diperoleh dari sensor mengandung *noise* dan fluktuasi yang dapat mengganggu proses klasifikasi. Sehingga dilakukan tahap pra-pemrosesan untuk meningkatkan kualitas data. Sinyal denyut nadi digunakan untuk merepresentasikan kondisi fisiologis pengendara, diekstraksi menggunakan pendekatan statistik untuk implementasi *real-time*. Pulse sensor membaca sinyal denyut nadi dalam bentuk analog dan mengubahnya menjadi digital dalam satuan Beats per Minute (BPM).

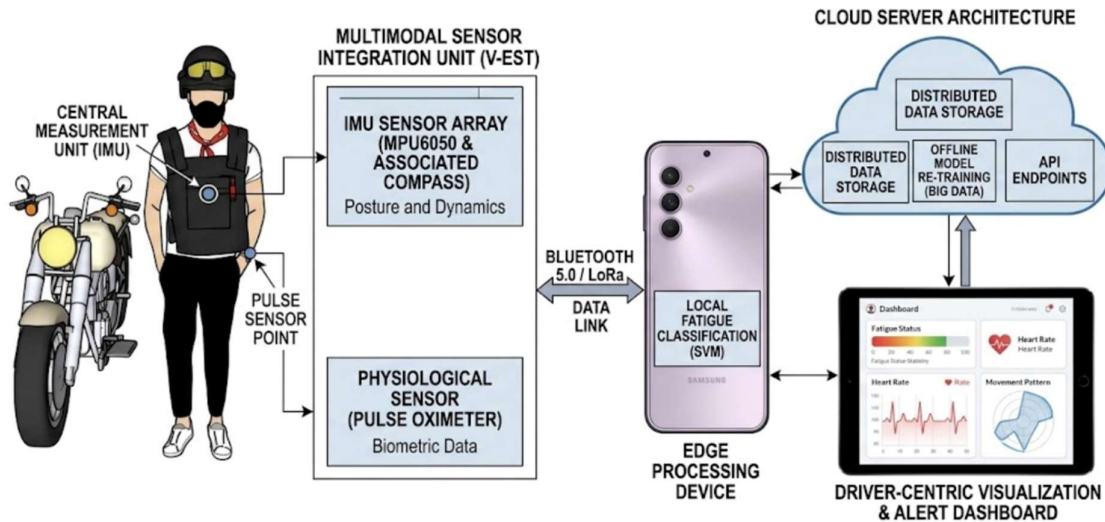
Fitur postur tubuh diekstraksi dari data sensor MPU6050. Perubahan orientasi dan kestabilan postur tubuh merupakan indikator penting dari kelelahan fisik yang menyebabkan menurunnya kontrol motorik. Fitur postur tubuh yang digunakan berupa rata-rata sudut orientasi tubuh, yang merepresentasikan posisi tubuh selama berkendara. Tabel 1 memperlihatkan pengkategorian fitur berdasarkan denyut jantung dan kemiringan postur.

Tabel 1. Fitur Pengkategorian Kondisi Pengendara Berdasarkan BPM dan Kemiringan Tubuh Pengendara

Denyut Nadi (BPM)	Kemiringan Tubuh (°)	Kondisi Pengendara
90 - 120	70 - 90	Normal
71 - 85	45 - 65	Mengantuk sedang
65 - 70	< 45	Mengantuk berat

Setelah fitur diekstraksi dari masing-masing modalitas, fitur denyut nadi dan fitur postur tubuh digabungkan menjadi satu vektor, yaitu fitur multimodal. Secara umum, vektor fitur direpresentasikan sebagai:

$$\mathbf{F} = \{\mu_{HR}, \sigma_{HR}, \Delta HR, \mu_{\theta}, \sigma_{\theta}, \Delta \theta\} \quad (1)$$



Gambar 2. Arsitektur Sistem

dengan μ menyatakan nilai rata-rata, σ menyatakan simpangan baku, dan Δ menyatakan perubahan antar jendela waktu. Integrasi fitur dari dua modalitas ini bertujuan untuk menangkap aspek fisiologis dan perilaku pengendara secara simultan, sehingga memberikan representasi kondisi kelelahan yang lebih komprehensif. Sebelum digunakan sebagai masukan model SVM, semua fitur dinormalisasi untuk memastikan kesetaraan skala antar fitur. Normalisasi dilakukan untuk mencegah fitur dengan rentang nilai besar mendominasi proses pembelajaran model.

2.3. Support Vector Machine

Proses klasifikasi kondisi kelelahan pengendara sepeda motor dilakukan menggunakan algoritma *Support Vector Machine* (SVM). SVM dipilih karena memiliki kemampuan generalisasi yang baik pada dataset berukuran kecil hingga menengah, stabil terhadap noise.

SVM merupakan algoritma klasifikasi yang bekerja dengan mencari *hyperplane* optimal dan mampu memisahkan data dari dua kelas dengan margin maksimum. Pada penelitian ini, digunakan tiga kelas sebagai indikator kelelahan, yaitu: kondisi normal, mengantuk sedang dan mengantuk berat. Keadaan mengantuk digunakan sebagai representasi dari tingkat kelelahan pengguna. Secara matematis, optimasi pada SVM sebagai berikut:

$$\min_{\mathbf{w}, b, \xi} \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^N \xi_i \quad (2)$$

dengan kendala:

$$y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i \quad (3)$$

di mana \mathbf{x}_i merupakan vektor fitur hasil ekstraksi multimodal, y_i merupakan label kelas, ξ_i adalah variabel *slack* untuk mengakomodasi kesalahan klasifikasi, dan C adalah parameter

regulasi yang mengontrol keseimbangan antara margin dan tingkat kesalahan. Nilai parameter C yang tepat sangat berpengaruh terhadap kemampuan generalisasi model.


Untuk menangani kemungkinan hubungan non-linear antara fitur-fitur multimodal dan kondisi kelelahan, penelitian ini menggunakan fungsi kernel *Radial Basis Function* (RBF). Kernel RBF memungkinkan pemetaan data ke ruang berdimensi lebih tinggi sehingga data yang tidak terpisahkan secara linear dapat diklasifikasikan dengan lebih baik. Fungsi kernel RBF didefinisikan sebagai:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (4)$$

dengan γ merupakan parameter yang mengontrol pengaruh satu sampel terhadap sampel lainnya. Kombinasi parameter C dan γ menentukan kompleksitas model dan performa klasifikasi secara keseluruhan.

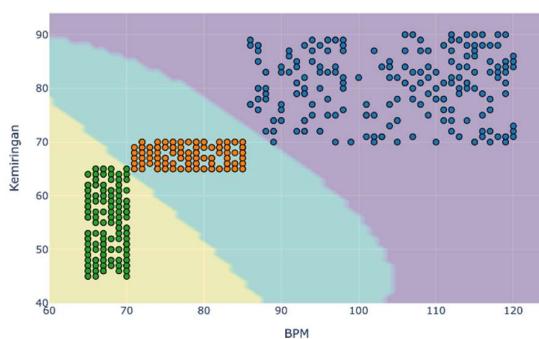
2.3.1. Dataset

Dataset terdiri atas 600 entri data, dengan dua fitur utama sebagai variabel input, yaitu denyut nadi (BPM) dan sudut kemiringan postur tubuh. Fitur denyut nadi (BPM) merepresentasikan indikator fisiologis pengendara, sedangkan fitur kemiringan postur tubuh merepresentasikan indikator perilaku yang mencerminkan kondisi fisik pengendara selama berkendara. Variabel target pada dataset ini adalah kondisi mengantuk, yang dibagi ke dalam tiga kelas, yaitu normal, mengantuk sedang, dan mengantuk berat, masing-masing dengan jumlah 200 sampel. Dengan distribusi kelas yang seimbang pada setiap kategori, dataset ini termasuk dalam *balanced* dataset, sehingga sesuai untuk pelatihan dan evaluasi model klasifikasi tanpa bias terhadap kelas tertentu. Gambar 3 memperlihatkan distribusi kelas pada dataset.



Gambar 3. Distribusi Kelas pada Dataset

Analisis *box-plot* menunjukkan bahwa fitur BPM dan kemiringan postur tubuh memiliki distribusi yang berbeda secara jelas pada setiap kelas kelelahan, dengan nilai tertinggi pada kelas normal dan terendah pada kelas mengantuk berat. Pergeseran median dan *interquartile range* pada kedua fitur menunjukkan penurunan bertahap seiring meningkatnya tingkat kantuk pengendara. Pemisahan distribusi yang konsisten antar kelas ini mengindikasikan bahwa BPM dan kemiringan postur tubuh memiliki daya diskriminasi yang tinggi dan efektif digunakan sebagai fitur input dalam model klasifikasi kelelahan.



Gambar 4. Sebaran Data BPM dan Kemiringan Tubuh pada Klasifikasi Berbasis SVM

Gambar 4 menunjukkan sebaran denyut nadi (BPM) dan kemiringan postur tubuh pada setiap kelas kelelahan. Pada Gambar 4 terlihat pola pemisahan kelas yang jelas antar tingkat kelelahan pengendara. Data dengan nilai BPM tinggi, umumnya berada pada rentang 90–120 BPM, cenderung berasosiasi dengan sudut kemiringan tubuh yang lebih besar (sekitar 70–90°), yang diklasifikasikan sebagai kondisi normal. Pada rentang menengah, yaitu BPM sekitar 75–85 dengan sudut kemiringan tubuh 60–70°, data membentuk kluster tersendiri yang merepresentasikan

kondisi mengantuk sedang. Sementara itu, data dengan BPM lebih rendah, sekitar 65–75 BPM, dan sudut kemiringan tubuh yang lebih kecil (45–60°) terkonsentrasi pada wilayah mengantuk berat. Pola sebaran ini mengindikasikan bahwa kombinasi fitur BPM dan kemiringan tubuh bersifat saling melengkapi serta memiliki daya diskriminasi yang baik untuk membedakan tingkat kelelahan pengendara.

2.3.2. Pelatihan Model dan Evaluasi

Pelatihan model SVM menggunakan data fitur multimodal yang telah dinormalisasi. Dataset dibagi menjadi data latih dan data uji untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Selama proses pelatihan, model mempelajari pola keterkaitan antara fitur denyut nadi dan fitur postur tubuh dengan label kondisi pengendara.


Validasi silang (*cross-validation*) dengan metode *k-fold*, dilakukan untuk mengurangi *overfitting* dengan membagi data latih menjadi beberapa subset dan digunakan secara bergantian sebagai data validasi. Sehingga model tidak hanya berkinerja baik pada subset tertentu, tetapi juga stabil terhadap variasi data. Pendekatan multimodal pada penelitian ini diterapkan pada tingkat fitur (*feature-level fusion*), yakni dengan menggabungkan fitur denyut nadi dan fitur postur tubuh ke dalam satu vektor fitur tunggal sebelum proses klasifikasi. Integrasi multimodal diharapkan meningkatkan akurasi dan ketahanan sistem terhadap gangguan atau ketidakpastian pada salah satu sensor. Sehingga, hasil klasifikasi tidak hanya bergantung pada satu parameter, namun lebih komprehensif.

Kinerja model SVM dievaluasi menggunakan beberapa metrik: akurasi, presisi, *recall*, dan *F1-score*. Akurasi digunakan untuk mengukur tingkat keberhasilan klasifikasi secara keseluruhan, sedangkan presisi dan *recall* memberikan informasi yang lebih spesifik terkait kemampuan model dalam mendeteksi kondisi kelelahan secara tepat. *F1-score* digunakan sebagai metrik keseimbangan antara presisi dan *recall*, terutama pada kondisi distribusi kelas yang tidak sepenuhnya seimbang. *Confusion Matrix* digunakan untuk menganalisis kesalahan klasifikasi yang terjadi, sehingga dapat diketahui pola kesalahan pada model.

3. HASIL

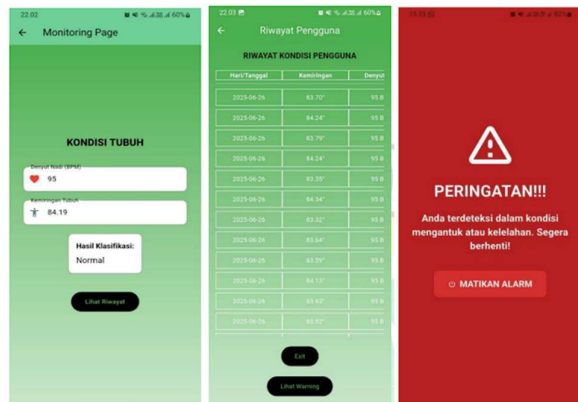
3.1. Implementasi Sistem

Implementasi sistem deteksi kelelahan pengendara sepeda motor terdiri atas dua komponen utama, yaitu implementasi perangkat keras dan implementasi perangkat lunak yang saling terintegrasi untuk memonitor kondisi pengendara secara *real-time*.



Gambar 5. Implementasi Sistem Pada Unit-Rompi dan Unit-Gelang Tangan

Pada sisi perangkat keras, sistem dibangun menggunakan dua unit *wearable*, yaitu unit rompi (*vest unit*) dan unit gelang (*wrist unit*). Unit rompi berfungsi sebagai pusat pemrosesan data menggunakan mikrokontroler ESP32 dan sensor MPU6050 untuk memperoleh orientasi postur tubuh pengendara selama berkendara. Unit gelang berfungsi sebagai antarmuka pemantauan fisiologis pengendara dan dilengkapi dengan sensor pulse BPM secara *real-time*. Data denyut nadi yang diperoleh diproses oleh mikrokontroler dan kemudian dikirimkan ke perangkat *smartphone* melalui komunikasi nirkabel berbasis Bluetooth. Implementasi sistem pada unit-rompi dan unit-gelang dapat dilihat pada Gambar 5.



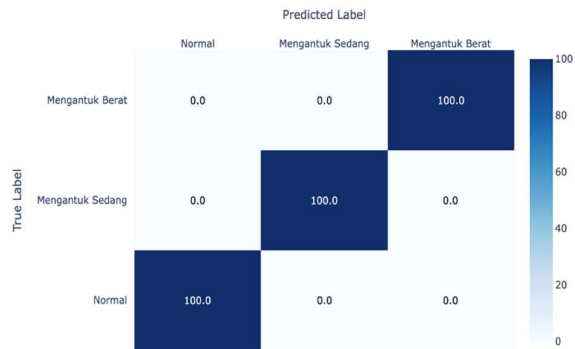
Gambar 6. Implementasi *User-Interface* Pada Perangkat Android

Pada sisi perangkat lunak, sistem dikembangkan dengan pendekatan *edge computing* untuk memastikan waktu respons yang cepat dan mendukung penerapan klasifikasi secara *real-time*. Perangkat *smartphone* berperan sebagai perangkat pemrosesan tepi yang menjalankan model SVM secara langsung (*on-device*). Model SVM yang digunakan telah dilatih menggunakan fitur multimodal mengidentifikasi tingkat kelelahan pengendara. Selain itu, aplikasi Android dirancang sebagai antarmuka pengguna yang menampilkan informasi kondisi pengendara, riwayat pemantauan, serta sistem peringatan dini yang akan aktif secara otomatis ketika terdeteksi indikasi kelelahan dengan kategori mengantuk sedang dan mengantuk berat. Komunikasi data antara perangkat *wearable* dan *smartphone* dilakukan melalui koneksi Bluetooth, sedangkan sinkronisasi data dengan penyimpanan terdistribusi (*distributed*

storage) digunakan untuk mendukung proses pelatihan ulang model secara *offline*. Implementasi aplikasi Apps pada perangkat Android dapat dilihat pada Gambar 6.

3.2. Implementasi SVM

Dataset dibagi menjadi 80% data latih dan 20% data uji. Hasil evaluasi menunjukkan bahwa model SVM mampu mengklasifikasikan kondisi pengendara dengan akurasi 100%. Gambar 7 memperlihatkan *confusion matrix* dari SVM, dan Tabel 2 menunjukkan nilai akurasi, presisi, recall dan F1-score model SVM. Pada Tabel 2 menampilkan hasil akurasi, presisi, recall dan F1-score model SVM dengan fitur multimodal (denyut nadi dan postur tubuh).



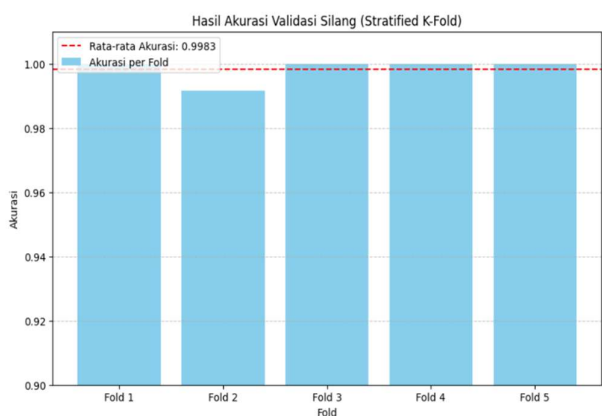
Gambar 7. *Confusion Matrix* SVM

Tabel 2. Nilai Akurasi, Presisi, Recall, F1-Score Model SVM dengan Fitur Multimodal (Denyut Nadi, Postur Tubuh)

Kelas	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Normal	100	100	100	100
Mengantuk sedang	100	100	100	100
Mengantuk berat	100	100	100	100
Rata-rata	100	100	100	100

Hasil validasi silang (*cross-validation*) menggunakan lima *fold* menunjukkan bahwa model Support SVM memiliki kinerja yang sangat tinggi dan konsisten, dengan nilai akurasi masing-masing *fold* sebesar 100%, 99,17%, 100%, 100%, dan 100%. Rata-rata akurasi validasi silang mencapai 99,83% dengan standar deviasi sebesar 0,33%. Hal ini mengindikasikan model memiliki variabilitas kinerja yang sangat rendah terhadap perbedaan pembagian data dan bersifat robust. Gambar 8 menunjukkan hasil *cross-validation* dengan 5-*fold*.

Visualisasi bar plot, seperti diperlihatkan Gambar 8, memperlihatkan kesamaan nilai akurasi yang hampir mencapai 100% pada seluruh *fold* serta garis rata-rata yang berada dekat batas maksimum, sehingga memperkuat bahwa model SVM mampu melakukan generalisasi dengan baik berdasarkan fitur denyut nadi dan kemiringan postur tubuh menggunakan dataset yang telah disusun.



Gambar 8. Hasil Cross-Validation 5-Fold

Pada tahap inferensi waktu nyata, model SVM yang telah dilatih dimuat ke dalam memori sistem untuk digunakan dalam proses klasifikasi secara langsung. Setiap kali fitur hasil pra-pemrosesan, yaitu denyut nadi (BPM) dan kemiringan postur tubuh, tersedia, sistem secara otomatis meneruskannya ke model SVM. Model kemudian mengklasifikasikan data tersebut ke dalam salah satu kelas kondisi pengendara, yaitu normal, mengantuk sedang, atau mengantuk berat.

Pada implementasi, latensi inferensi pada *edge-device* (ESP32) rata-rata 47 ms per siklus. Latensi ini berada di bawah batas 500 ms yang ditetapkan sebagai syarat responsivitas sistem peringatan *real-time*. Konsumsi daya perangkat wearable berada pada kisaran 3,20 mW, memungkinkan operasi selama ± 3 jam 30 menit dengan baterai Li-Po 1000 mAh.

4. PEMBAHASAN

Untuk membandingkan akurasi model SVM dengan fitur unimodal, yaitu: unimodal-denyut nadi dan unimodal-postur dengan fitur multimodal (denyut nadi dan postur), dilakukan eksperimen dengan tiga konfigurasi: (a) SVM hanya menggunakan fitur denyut nadi (unimodal-HR), (b) SVM hanya menggunakan fitur postur tubuh (unimodal-Posture), dan (c) SVM menggunakan fitur multimodal gabungan. Tabel 3 menampilkan hasil akurasi, presisi, recall dan F1-score model SVM dengan fitur unimodal denyut nadi dan Tabel 4 menampilkan hasil akurasi, presisi, recall dan F1-score model SVM dengan fitur unimodal postur tubuh.

Perbandingan kinerja model antara unimodal dan multimodal pada dilihat pada Tabel 2, Tabel 3 dan Tabel 4. Model SVM yang menggunakan fitur unimodal fitur denyut nadi (BPM) mampu mencapai akurasi sebesar 99.7% dengan misklasifikasi pada kelas mengantuk berat. Sementara itu, model yang menggunakan fitur unimodal kemiringan postur tubuh menghasilkan akurasi sebesar 95,5% dan mengalami beberapa misklasifikasi, khususnya pada kelas mengantuk sedang dan mengantuk berat. Hal ini mengindikasikan keterbatasan fitur tunggal dalam merepresentasikan kondisi kelelahan secara menyeluruh. Meskipun kinerja berbasis BPM saja menunjukkan hasil akurasi yang tinggi pada dataset ini, pendekatan multimodal yang menggabungkan BPM dan kemiringan postur tubuh tetap dipilih karena memberikan representasi kondisi pengendara yang

lebih baik dan meningkatkan redundansi informasi. Sehingga akan memiliki kemampuan generalisasi yang lebih baik pada kondisi dunia nyata yang lebih bervariasi.

Pendekatan multimodal yang menggabungkan kedua jenis fitur menunjukkan peningkatan kinerja secara keseluruhan. Integrasi fitur denyut nadi dan postur tubuh memberikan representasi kondisi pengendara yang lebih komprehensif, sehingga model SVM dapat membedakan kondisi normal, mengantuk sedang dan mengantuk berat dengan lebih akurat. Namun, tingginya nilai evaluasi ini juga dipengaruhi oleh jumlah dan keragaman data uji yang terbatas, sehingga penelitian lanjutan dengan dataset yang lebih besar diperlukan untuk menguji kemampuan generalisasi model.

Tabel 3. Nilai Akurasi, Presisi, Recall, F1-Score Model SVM dengan Fitur Unimodal Denyut Nadi

Kelas	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Normal	100	100	100	100
Mengantuk sedang	100	100	100	100
Mengantuk berat	99	98	98	99
Rata-rata	99.7	99.3	99.3	99.7

Tabel 4. Nilai Akurasi, Presisi, Recall, F1-Score Model SVM dengan Fitur Unimodal Postur Tubuh

Kelas	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Normal	100	100	100	100
Mengantuk sedang	93.3	83.3	100	90.9
Mengantuk berat	93.3	100	80	88.9
Rata-rata	95.5	94.4	93.3	93.3

Perbandingan hasil menunjukkan bahwa pendekatan multimodal memiliki nilai akurasi, presisi, *recall*, dan *F1-score* yang lebih tinggi dibandingkan pendekatan unimodal. Peningkatan ini terutama terlihat pada kemampuan sistem dalam mendeteksi kondisi lelah secara benar (*true positive*), yang ditunjukkan oleh nilai *recall* kelas lelah yang lebih tinggi. Hasil ini menunjukkan bahwa kelelahan pengendara tidak dapat direpresentasikan secara optimal hanya dengan satu jenis sinyal. Sinyal fisiologis dan perilaku memiliki karakteristik yang saling melengkapi. Ketika salah satu sensor mengalami gangguan atau ketidakpastian, modalitas lain masih dapat memberikan informasi yang relevan untuk mendukung keputusan klasifikasi.

Pengujian sistem dilakukan pada skenario berkendara langsung di jalan dengan mempertimbangkan kondisi jalan yang umum dilalui pengendara sepeda motor. Subjek melakukan perjalanan dalam rentang waktu tertentu tanpa intervensi sistem peringatan agar kondisi kelelahan dapat dianalisis secara alami. Pendekatan ini bertujuan untuk menguji keandalan sistem dalam mendeteksi kelelahan pada kondisi penggunaan sebenarnya.

Pengujian dilakukan menggunakan enam data sampel yang mewakili variasi denyut nadi dan sudut postur tubuh pengendara. Sistem mampu mengklasifikasikan kondisi normal pada denyut nadi tinggi dengan postur tubuh stabil tanpa mengaktifkan alarm. Pada kondisi denyut nadi yang lebih rendah disertai penurunan sudut postur, sistem berhasil mendeteksi kelelahan tingkat sedang dan berat serta mengaktifkan alarm sebagai peringatan. Seluruh hasil klasifikasi dan respons alarm menunjukkan kesesuaian dengan kondisi yang diharapkan, sehingga sistem dinilai mampu

mendeteksi tingkat kelelahan pengendara secara tepat. Hasil pengujian sistem dapat dilihat pada Tabel 5.

Tabel 5. Hasil Pengujian Sistem

Denyut Nadi (BPM)	Kemiringan Tubuh ($^{\circ}$)	Hasil Klasifikasi	Status Notifikasi	Keterangan
86	80	Normal	Tidak aktif	Sesuai
85	75	Normal	Tidak aktif	Sesuai
72	64	Mengantuk sedang	Aktif	Sesuai
73	65	Mengantuk sedang	Aktif	Sesuai
69	64	Mengantuk berat	Aktif	Sesuai
69	62	Mengantuk berat	Aktif	Sesuai

Tabel 6. Analisis Kasus Kegagalan Klasifikasi

Kondisi	Kelas Aktual	Kelas Prediksi	Penyebab Dugaan
Hujan ringan	Normal	Mengantuk sedang	Noise akibat tetesan air
Jalan bergelombang	Mengantuk sedang	Normal	Motion spike BPM sesaat
Manuver menikung	Normal	Mengantuk sedang	Kemiringan adaptif salah klasifikasi

Sistem deteksi kelelahan berbasis multimodal mampu mencapai tingkat akurasi sebesar 100% pada kondisi pengujian standar. Namun, analisis lebih lanjut terhadap kasus kegagalan klasifikasi menunjukkan kegagalan klasifikasi akibat pengaruh kondisi cuaca hujan dan noise pada sinyal sensor.

Pada kondisi hujan, tetesan air hujan yang mengenai permukaan rompi pengendara menimbulkan getaran tambahan yang memicu noise mekanik pada sensor MPU6050, sehingga menyebabkan perubahan pembacaan sudut kemiringan yang berbeda dengan kondisi aktual. Disamping itu, kondisi lingkungan yang basah dan bersuhu lebih rendah dapat memengaruhi respons fisiologis pengendara, khususnya pada pembacaan denyut nadi. Fenomena ini menyebabkan perubahan amplitudo sinyal *pulse sensor*, yang berpotensi menghasilkan nilai BPM yang tidak sesuai dengan kondisi sebenarnya. Tabel 6 menunjukkan analisis hasil kegagalan klasifikasi pada kondisi pengujian yang tidak standar. Selain itu, noise sensor akibat artefak gerak (*motion artifacts*) juga menjadi faktor signifikan yang memengaruhi akurasi klasifikasi, terutama pada sensor pulse yang dipasang di pergelangan tangan. Gerakan tangan seperti saat pengereman mendadak, manuver menikung tajam akan menghasilkan lonjakan sinyal (*spike*) pada data BPM yang tidak berhubungan langsung dengan tingkat kelelahan.

5. DISKUSI

Pemilihan SVM sebagai metode klasifikasi terbukti efektif untuk dataset yang digunakan dalam penelitian ini. SVM mampu menghasilkan batas keputusan yang jelas antara dua kelas meskipun jumlah data relatif terbatas. Namun, kinerja model SVM sangat bergantung pada kualitas fitur yang diekstraksi. *Feature engineering* yang tepat berperan penting dalam

memastikan bahwa informasi fisiologis dan perilaku yang relevan dapat dimanfaatkan secara optimal oleh model.

Hasil penelitian ini menunjukkan bahwa sistem deteksi kelelahan berbasis *wearable* dengan pendekatan multimodal memiliki potensi besar untuk diaplikasikan sebagai sistem peringatan dini bagi pengendara sepeda motor. Sistem ini bersifat non-intrusif, dapat bekerja secara real-time, dan relatif tahan terhadap perubahan kondisi lingkungan. Namun, penelitian ini masih memiliki beberapa keterbatasan. Jumlah subjek dan durasi pengambilan data yang berdasarkan durasi berkendara dan observasi, sehingga belum sepenuhnya merepresentasikan tingkat kelelahan subjektif pengendara. Pengembangan dataset yang lebih besar dan beragam serta integrasi metode pelabelan yang lebih objektif menjadi arah penelitian selanjutnya.

6. KESIMPULAN

Penelitian ini mengajukan sebuah sistem deteksi kelelahan pengendara sepeda motor berbasis *wearable* dengan pendekatan multimodal, yang mengintegrasikan sinyal denyut nadi dan postur tubuh menggunakan algoritma Support Vector Machine (SVM). Sistem dirancang untuk bekerja secara *real-time* dan non-intrusif, sehingga sesuai untuk digunakan pada skenario berkendara nyata dengan dinamika lingkungan yang tinggi.

Hasil eksperimen menunjukkan bahwa pendekatan multimodal memberikan kinerja klasifikasi yang lebih baik dan lebih stabil dibandingkan pendekatan unimodal. Integrasi fitur fisiologis dan perilaku mampu merepresentasikan kondisi kelelahan pengendara secara lebih komprehensif, sehingga meningkatkan akurasi, presisi, *recall*, dan *F1-score* dalam mendeteksi kondisi

lelah. Model SVM dengan kernel RBF terbukti efektif dalam memisahkan dua kelas kondisi pengendara meskipun jumlah data relatif terbatas. Meskipun sistem yang diusulkan menunjukkan hasil yang menjanjikan, masih terdapat beberapa peluang pengembangan untuk penelitian selanjutnya. Jumlah subjek dan keragaman data dapat diperluas untuk meningkatkan kemampuan generalisasi model terhadap berbagai karakteristik pengendara dan kondisi berkendara yang berbeda. Penelitian selanjutnya dapat mengeksplorasi fitur non-linear atau fitur berbasis *heart rate variability* yang lebih kompleks. Keterbatasan utama penelitian ini adalah ukuran dataset yang masih terbatas dan tidak mencakup variasi kondisi jalan yang lebih ekstrem. Penelitian lanjutan dengan dataset yang lebih besar dan beragam diperlukan untuk meningkatkan kemampuan generalisasi model.

DAFTAR PUSTAKA

- [1] Y. Albadawi, M. Tahruri, and M. Awad, "A Review of Recent Developments in Driver Drowsiness Detection Systems," *Sensors*, vol. 22, no. 5, p. 2069, Mar. 2022, doi: [10.3390/s22052069](https://doi.org/10.3390/s22052069).
- [2] M. S. AL-Quraishi, S. S. Azhar Ali, M. AL-Qurishi, T. B. Tang, and S. Elferik, "Technologies for detecting and monitoring drivers' states: A systematic review," *Heliyon*, vol. 10, no. 20, p. e39592, Oct. 2024, doi: [10.1016/j.heliyon.2024.e39592](https://doi.org/10.1016/j.heliyon.2024.e39592).
- [4] T. Fonseca and S. Ferreira, "Drowsiness Detection in Drivers: A Systematic Review of Deep Learning-Based Models," *Appl. Sci.*, vol. 15, no. 16, p. 9018, Jan. 2025, doi: [10.3390/app15169018](https://doi.org/10.3390/app15169018).
- [5] J. Halomoan, K. Ramli, D. Sudiana, T. S. Gunawan, and M. Salman, "ECG-Based Driving Fatigue Detection Using Heart Rate Variability Analysis with Mutual Information," *Information*, vol. 14, no. 10, p. 539, Oct. 2023, doi: [10.3390/info14100539](https://doi.org/10.3390/info14100539).
- [6] Y. Jiao, C. Zhang, X. Chen, L. Fu, C. Jiang, and C. Wen, "Driver Fatigue Detection Using Measures of Heart Rate Variability and Electrodermal Activity," *IEEE Trans. Intell. Transp. Syst.*, vol. 25, no. 6, pp. 5510–5524, Jun. 2024, doi: [10.1109/TITS.2023.3333252](https://doi.org/10.1109/TITS.2023.3333252).
- [7] D. I. Putra, D. Suarmin, and S. Ekariani, "Fatigue Warning System During Physical Exercise Based on Heart Rate and Oxygen Saturation Using Non-invasive Wearable Sensor," in *2022 International Symposium on Information Technology and Digital Innovation (ISITDI)*, Jul. 2022, pp. 22–26. doi: [10.1109/ISITDI55734.2022.9944484](https://doi.org/10.1109/ISITDI55734.2022.9944484).
- [8] D. Ichwana, R. Z. Ikhlas, and S. Ekariani, "Heart Rate Monitoring System During Physical Exercise for Fatigue Warning Using Non-invasive Wearable Sensor," in *2018 International Conference on Information Technology Systems and Innovation (ICITSI)*, Oct. 2018, pp. 497–502. doi: [10.1109/ICITSI.2018.8696039](https://doi.org/10.1109/ICITSI.2018.8696039).
- [9] C. Lin, X. Zhu, R. Wang, W. Zhou, N. Li, and Y. Xie, "Early Driver Fatigue Detection System: A Cost-Effective and Wearable Approach Utilizing Embedded Machine Learning," *Vehicles*, vol. 7, no. 1, p. 3, Mar. 2025, doi: [10.3390/vehicles7010003](https://doi.org/10.3390/vehicles7010003).
- [10] Z. AlArnaout, C. Zaki, Y. Kotb, M. AlAkkoumi, and N. Mostafa, "Exploiting heart rate variability for driver drowsiness detection using wearable sensors and machine learning," *Sci. Rep.*, vol. 15, no. 1, p. 24898, Jul. 2025, doi: [10.1038/s41598-025-08582-2](https://doi.org/10.1038/s41598-025-08582-2).
- [11] M. R. Yazid, A. N. Jaafar, R. Abdullah, N. N. S. N. Dzulkefli, and S. Omar, "Real-Time Heart Rate Monitoring Using Arduino and Pulse Sensor," in *2024 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)*, Jun. 2024, pp. 368–372. doi: [10.1109/I2CACIS61270.2024.10649849](https://doi.org/10.1109/I2CACIS61270.2024.10649849).
- [12] I. A. Soenandi, L. Widodo, B. Harsono, I. Oktavera, and V. Lusiana, "Fatigue analysis and design of a motorcycle online driver measurement tool using real-time sensors," *J. Sist. Dan Manaj. Ind.*, vol. 7, no. 2, pp. 169–178, Dec. 2023, doi: [10.30656/jsmi.v7i2.7500](https://doi.org/10.30656/jsmi.v7i2.7500).
- [13] S. Hwang *et al.*, "A Multimodal Fatigue Detection System Using sEMG and IMU Signals with a Hybrid CNN-LSTM-Attention Model," *Sensors*, vol. 25, no. 11, p. 3309, Jan. 2025, doi: [10.3390/s25113309](https://doi.org/10.3390/s25113309).
- [14] H. Luo, P.-A. Lee, I. Clay, M. Jaggi, and V. De Luca, "Assessment of Fatigue Using Wearable Sensors: A Pilot Study," *Digit. Biomark.*, vol. 4, no. Suppl 1, pp. 59–72, Nov. 2020, doi: [10.1159/000512166](https://doi.org/10.1159/000512166).
- [15] N. R. Adão Martins, S. Annaheim, C. M. Spengler, and R. M. Rossi, "Fatigue Monitoring Through Wearables: A State-of-the-Art Review," *Front. Physiol.*, vol. 12, p. 790292, Dec. 2021, doi: [10.3389/fphys.2021.790292](https://doi.org/10.3389/fphys.2021.790292).