Pemantauan Kelelahan Fisiologis Pengemudi Truk Berbasis Machine Learning Menggunakan Heart Rate Variability (Hrv) Pada Perangkat Iot

I Wayan Arya Wiranatha
Prodi S1 Teknik Telekomunikasi
Universitas Telkom
Bandung, Indonesia
mcnuugtt@student.telkomuniversity.ac.id

Alya Mafira
Prodi S1 Teknik Telekomunikasi
Universitas Telkom
Bandung, Indonesia
alyamafira@student.telkomuniversity.ac.id

Naisya Aghis Nabila
Prodi S1 Teknik Telekomunikasi
Universitas Telkom
Bandung, Indonesia
nsyaghis@student.telkomuniversity.ac.id

Riska Agus
Prodi S1 Teknik Telekomunikasi
Universitas Telkom
Bandung, Indonesia
riskaagus@student.telkomuniversity.ac.id

Inung Wijayanto
Prodi S1 Teknik Telekomunikasi
Universitas Telkom
Bandung, Indonesia
iwijayanto@telkomuniversity.ac.id

Sugondo Hadiyoso
Prodi S1 Teknik Telekomunikasi
Universitas Telkom
Bandung, Indonesia
sugondo@telkomuniversity.ac.id

Abstrak—Keselamatan transportasi darat di Indonesia masih jauh dari kata aman. Data Pusat Informasi Kriminal Nasional (Pusiknas) Bareskrim Polri mencatat lebih dari 17.280 truk/tronton terlibat kecelakaan dari 118.452 kejadian di seluruh Indonesia sepanjang Januari–November 2024, dan kelelahan pengemudi diperkirakan berkontribusi 20–25% dari total kejadian tersebut. Berangkat dari persoalan ini, penelitian ini mengembangkan sistem pemantauan kelelahan fisiologis pengemudi truk berbasis Internet of Things (IoT) dan Machine Learning menggunakan parameter Heart Rate Variability (HRV). Sinyal EKG diakuisisi melalui sensor AD8232 dan ESP32 pada rompi wearable, lalu diproses oleh Raspberry Pi 4 yang mendeteksi R-peak menggunakan algoritma Pan-Tompkins dan mengekstraksi fitur HRV domain waktu—SDNN, RMSSD, dan pNN50—pada jendela 60 detik sebagai masukan model klasifikasi Random Forest. Hasil klasifikasi beserta data HRV kemudian disinkronisasikan secara real-time ke platform cloud Supabase dan ditampilkan pada aplikasi mobile SafeDrive berbasis Flutter. Optimasi hyperparameter dilakukan melalui Grid Search 432 kombinasi dengan 5-Fold Stratified Cross Validation, sementara threshold klasifikasi ditentukan menggunakan Youden's Index. Hasilnya, model akhir memperoleh akurasi 79,52%, spesifisitas 84,51%, dan recall 50% pada data uji (166 sampel), dengan SDNN sebagai fitur yang paling berpengaruh (42,0%). Pengujian pada perangkat keras, integrasi cloud, dan aplikasi mobile menunjukkan seluruh subsistem berfungsi sesuai spesifikasi—sebuah indikasi bahwa sistem ini berpotensi menjadi solusi yang efektif untuk meningkatkan keselamatan transportasi kendaraan berat di Indonesia.

Kata kunci—Heart Rate Variability, Internet of Things, Kelelahan Pengemudi, Machine Learning, Random Forest

I. PENDAHULUAN

Truk dan tronton kerap menjadi sorotan setiap kali statistik kecelakaan lalu lintas di Indonesia dirilis. Data Pusat Informasi Kriminal Nasional (Pusiknas) Bareskrim Polri mencatat 17.280 truk/tronton terlibat kecelakaan sepanjang 1 Januari hingga 4 November 2024, dari total 118.452 kejadian di seluruh Indonesia [2]. Sebagian besar penyebabnya bukan faktor teknis kendaraan, melainkan faktor manusia—terutama kelelahan dan kantuk akibat beban kerja yang berat serta durasi mengemudi yang panjang, dengan kontribusi diperkirakan mencapai 20–25% dari seluruh kejadian [1], [3]. Begitu kewaspadaan menurun, kemampuan kognitif dan kecepatan pengambilan keputusan pengemudi ikut menurun, dan risiko kecelakaan pun meningkat.

Sejumlah pendekatan sebenarnya sudah diusulkan untuk mendeteksi kelelahan pengemudi lebih dini. Secara umum pendekatan tersebut terbagi menjadi tiga kelompok: berbasis perilaku/kamera, berbasis kendaraan, dan berbasis sinyal fisiologis [6]. Sistem berbasis kamera dan computer vision paling banyak dikembangkan [7], tetapi akurasinya sangat bergantung pada kondisi pencahayaan, sudut pengambilan gambar, dan kenyamanan pengemudi yang harus terus-menerus direkam. Metode berbasis pola mengemudi (deviasi lajur, pola kemudi) juga memiliki kelemahan mendasar: baru terdeteksi setelah performa berkendara benar-benar menurun, sehingga sifatnya reaktif, bukan preventif. Sampai saat ini belum tersedia sistem yang benar-benar mampu memantau kondisi fisiologis pengemudi secara objektif dan real-time selama perjalanan berlangsung.

Persoalan ini sebenarnya bisa dilihat dari beberapa sudut sekaligus. Dari sisi teknis, akuisisi sinyal biopotensial pada kondisi kendaraan yang terus bergerak sangat rentan terhadap gangguan getaran dan electromagnetic noise, sehingga dibutuhkan pemrosesan sinyal yang cukup andal untuk tetap bisa mendeteksi R-peak secara akurat [5]. Dari sisi kesehatan dan fisiologis, kelelahan mengganggu

keseimbangan sistem saraf otonom, dan gangguan itu bisa diidentifikasi lewat parameter HRV—cara yang jauh lebih objektif dibandingkan menilai kelelahan dari penampilan atau pengakuan pengemudi sendiri [4], [10]. Ada pula sisi ekonomi dan sosial yang sering luput dari perhatian: kecelakaan truk tidak hanya merusak kendaraan dan menghilangkan muatan, tetapi juga membebani infrastruktur dan menimbulkan dampak sosial yang panjang bagi keluarga korban. Sementara dari sisi regulasi, batas waktu berkendara sebenarnya sudah diatur dalam Undang-Undang Nomor 22 Tahun 2009 dan Peraturan Menteri Perhubungan Nomor PM 118 Tahun 2018, tetapi penerapannya di lapangan masih jauh dari optimal karena minimnya pemantauan yang sifatnya objektif.

Di sinilah Heart Rate Variability (HRV) menjadi menarik untuk dilirik. HRV adalah variasi interval waktu antar detak jantung, dan karena mencerminkan keseimbangan saraf simpatis dan parasimpatis, parameter ini bisa dipakai sebagai indikator objektif aktivitas sistem saraf otonom [8], [9]. Ketika seseorang mengemudi terlalu lama, regulasi sistem saraf otonomnya berubah, dan perubahan itu terekam pada pola variasi RR interval. Berbagai penelitian telah menunjukkan HRV dapat dimanfaatkan untuk mendeteksi tingkat kelelahan dan kantuk pengemudi jauh lebih objektif dibandingkan sekadar penilaian subjektif [4], [10], [27]. Yang membuatnya makin praktis, HRV dapat dipantau melalui perangkat Internet of Things (IoT) yang portable, sehingga pemantauan berlangsung langsung di dalam kabin kendaraan tanpa mengganggu aktivitas mengemudi itu sendiri.

Berangkat dari permasalahan tersebut, penelitian ini mengusulkan sebuah sistem pemantauan kelelahan fisiologis pengemudi truk yang mengintegrasikan beberapa komponen sekaligus: wearable vest dengan sensor EKG AD8232 dan ESP32, unit pemrosesan edge Raspberry Pi 4 yang menjalankan algoritma Pan-Tompkins untuk deteksi R-peak, model klasifikasi Machine Learning Random Forest, cloud database Supabase untuk sinkronisasi data real-time, serta aplikasi mobile SafeDrive berbasis Flutter untuk menampilkan hasil pemantauan sekaligus mengirim notifikasi peringatan dini kepada pengemudi maupun supervisor.

Ada tiga tujuan utama yang hendak dicapai. Pertama, merancang wearable vest yang stabil dan nyaman dipakai untuk akuisisi sinyal fisiologis selama berkendara. Kedua, membangun model klasifikasi kelelahan berbasis fitur HRV domain waktu—SDNN, RMSSD, dan pNN50—dengan akurasi yang cukup andal untuk diandalkan di lapangan. Ketiga, mengintegrasikan seluruh komponen tersebut ke dalam arsitektur IoT berbasis cloud dan aplikasi mobile, sehingga pemantauan benar-benar dapat berjalan secara real-time.

Agar penelitian tetap fokus, ruang lingkupnya dibatasi pada beberapa hal berikut. Analisis kelelahan hanya didasarkan pada fitur HRV domain waktu, yaitu SDNN, RMSSD, dan pNN50—bukan domain frekuensi atau nonlinier. Deteksi R-peak dijalankan menggunakan algoritma Pan-Tompkins pada Raspberry Pi 4, sementara klasifikasi kelelahan memakai model Machine Learning Random Forest. Pengujian sistem dilakukan pada lingkungan simulasi yang menyerupai kondisi kabin truk, bukan pada operasional kendaraan sesungguhnya di jalan raya. Sistem juga dilengkapi aplikasi mobile berbasis Flutter yang terhubung ke cloud untuk pemantauan dan notifikasi secara real-time.

II. KAJIAN TEORI

A. Heart Rate Variability dan RR Interval

RR interval merujuk pada selang waktu antara dua puncak gelombang R yang berurutan pada kompleks QRS sinyal EKG, dan dari situlah seluruh perhitungan HRV bermula. Secara fisiologis, pola RR interval mencerminkan bagaimana saraf simpatis dan parasimpatis saling mengimbangi dalam mengatur irama jantung [9]—keseimbangan yang pada gilirannya turut menggambarkan kondisi kardiovaskular secara umum [8]. Penelitian ini memilih metode domain waktu untuk ekstraksi fitur HRV karena kompleksitas komputasinya rendah, tidak membutuhkan transformasi sinyal yang rumit, dan karena itu cocok dijalankan secara real-time pada perangkat edge computing sekelas Raspberry Pi [11], [12].

B. Fitur HRV Domain Waktu: SDNN, RMSSD, dan pNN50

Tiga parameter domain waktu dipakai sebagai fitur pada penelitian ini. SDNN, singkatan dari Standard Deviation of NN Intervals, mengukur standar deviasi seluruh interval RR normal dan menggambarkan variasi denyut jantung secara keseluruhan. RMSSD (Root Mean Square of Successive Differences) dihitung dari akar kuadrat rata-rata kuadrat selisih dua interval RR yang berurutan, sehingga lebih merepresentasikan aktivitas saraf parasimpatis dibandingkan SDNN. Sementara itu, pNN50 menghitung persentase pasangan interval RR berurutan yang selisihnya melebihi 50 ms, sehingga sensitif terhadap perubahan aktivitas parasimpatis [11]. Ketiganya menjadi fitur masukan bagi model Machine Learning untuk membedakan kondisi pengemudi normal dari yang sudah mulai mengalami kelelahan.

C. Deteksi R-Peak: Algoritma Pan-Tompkins

Sebelum fitur HRV dapat dihitung, sinyal EKG mentah harus melalui tahap deteksi puncak R terlebih dahulu, dan untuk keperluan itu digunakan algoritma Pan-Tompkins. Algoritma ini bekerja melalui empat tahap berurutan—band-pass filtering, diferensiasi, penguadratan (squaring), dan moving window integration—yang bersama-sama membantu meningkatkan kualitas sinyal sekaligus mendeteksi kompleks QRS secara akurat walau sinyal diganggu noise atau artefak gerakan [5]. Tahapan lengkapnya ditunjukkan pada Gambar 6.

D. Random Forest dan Optimasi Hyperparameter

Random Forest dipilih sebagai algoritma klasifikasi karena karakteristiknya sebagai ensemble learning: sejumlah decision tree dibangun dari sampel data yang berbeda-beda, lalu hasil prediksinya digabungkan melalui majority voting. Pendekatan ini terbukti mengurangi overfitting dan cukup baik memodelkan hubungan non-linier [13], [14]. Agar performanya optimal, hyperparameter Random Forest dioptimasi menggunakan Grid Search, yang mengevaluasi seluruh kombinasi parameter dalam ruang pencarian melalui cross-validation [16]—pendekatan yang juga sudah terbukti efektif pada klasifikasi berbasis fitur HRV di penelitian lain [17].

E. *SMOTE untuk Ketidakseimbangan Kelas*

Masalah klasik pada dataset semacam ini adalah ketidakseimbangan kelas, dan solusi yang dipakai di sini adalah SMOTE (Synthetic Minority Over-sampling Technique), yang menghasilkan sampel sintetis pada kelas minoritas berdasarkan kedekatan antar data [15]. Satu hal yang perlu ditegaskan: SMOTE hanya diterapkan pada data latih, tidak pernah menyentuh data uji, agar tidak terjadi kebocoran data (data leakage).

F. *Youden's Index*

Untuk menentukan titik potong (threshold) klasifikasi biner yang optimal, penelitian ini memakai Youden's Index (J), ukuran statistik yang menyeimbangkan sensitivitas dan spesifisitas sekaligus [18], dengan rumus:

$$J = \text{Sensitivity} + \text{Specificity} - 1 \quad (1)$$

G. *Arsitektur Perangkat IoT*

Sinyal biopotensial jantung diakuisisi melalui sensor AD8232 dengan konfigurasi single-lead ECG tiga elektroda—Right Arm, Left Arm, dan Right Leg—yang ditempelkan pada wearable vest, sementara mikrokontroler ESP32 bertugas membaca dan mentransmisikan datanya [19], [20]. Dari sana data diteruskan ke Raspberry Pi 4, yang berperan sebagai unit edge computing untuk deteksi R-peak, ekstraksi fitur HRV, sekaligus klasifikasi Machine Learning. Pembersihan artefak pada sinyal RR interval mengacu pada kriteria deviasi fisiologis akibat detak jantung ektopik [25], sedangkan pemilihan panjang window 60 detik mengacu pada studi validasi analisis HRV jangka ultra-pendek dalam kondisi berkendara nyata [26].

H. *Cloud Database dan Aplikasi Mobile*

Sebagai cloud backend, sistem ini memakai Supabase—platform Backend-as-a-Service berbasis PostgreSQL—untuk sinkronisasi data HRV secara real-time, autentikasi pengguna, dan penyimpanan riwayat data yang nantinya dipakai untuk evaluasi Machine Learning [22]. Acuan spesifikasi Machine Learning sendiri mengikuti standar ISO/IEC 22989, yang menitikberatkan pada akurasi, transparansi, dan keandalan sistem AI [21]. Sementara itu, antarmuka aplikasi mobile SafeDrive dirancang mengikuti pendekatan Human-Centred Design berdasarkan ISO 9241-11 [23] dan ISO 9241-210 [24], demi memastikan usability dan kepuasan pengguna tetap terjaga.

III. METODE

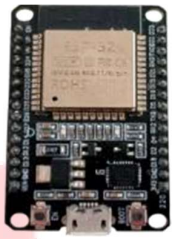
Penelitian ini memakai pendekatan eksperimental: sistem dirancang, diimplementasikan, kemudian dievaluasi secara bertahap untuk memantau kelelahan fisiologis pengemudi truk berbasis IoT dan Machine Learning menggunakan parameter HRV.

A. *Perangkat dan Spesifikasi Sistem*

Sistem SafeDrive dibangun di atas tiga komponen perangkat keras utama. Sensor AD8232 bersama elektroda ECG tiga lead menangkap sinyal biopotensial jantung pengemudi (Gambar 1); mikrokontroler ESP32 WROOM-32 membaca sinyal tersebut dan mentransmisikannya (Gambar 2); sementara Raspberry Pi 4 berperan sebagai unit edge computing yang menjalankan deteksi R-peak, ekstraksi fitur HRV, dan klasifikasi Machine Learning (Gambar 3).



GAMBAR 1
Sensor AD8232 dan Elektroda ECG



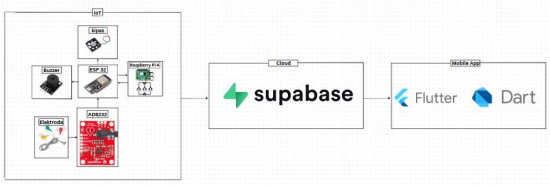
GAMBAR 2.
Mikrokontroler ESP32 WROOM-32



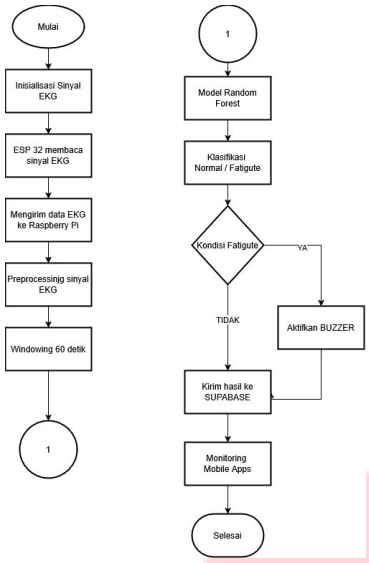
GAMBAR 3.
Raspberry Pi 4

B. *Rancangan Penelitian*

Secara keseluruhan, sistem dirancang sebagai satu pipeline end-to-end yang menyatukan wearable EKG, unit edge computing, model klasifikasi Machine Learning, cloud database, hingga aplikasi mobile. Gambar 4 memperlihatkan arsitektur sistem tersebut, sedangkan Gambar 5 menunjukkan diagram alur kerjanya secara lebih rinci.



GAMBAR 4
Arsitektur Sistem (IoT, Cloud Supabase, dan Mobile App Flutter/Dart)



GAMBAR 5
Diagram Alur Kerja Sistem SafeDrive

C. *Prosedur Penelitian*

Penelitian dilaksanakan melalui enam tahap. Pada tahap awal, sinyal EKG diakuisisi melalui sensor AD8232 dan ESP32 yang terpasang pada wearable vest, lalu dikirim ke Raspberry Pi 4 melalui komunikasi serial. Tahap berikutnya adalah preprocessing sinyal menggunakan band-pass Butterworth filter 5–15 Hz, dilanjutkan deteksi R-peak dengan algoritma Pan-Tompkins dan windowing non-overlapping 60 detik. Setelah itu, fitur HRV domain waktu (SDNN, RMSSD, pNN50) diekstraksi dari setiap window, data dibagi menjadi data latih (70%) dan data uji (30%) melalui stratified split, dan SMOTE diterapkan pada data latih untuk mengatasi ketidakseimbangan kelas. Tahap keempat berupa optimasi hyperparameter Random Forest melalui Grid Search dan evaluasi 5-Fold Stratified Cross Validation, diikuti penentuan threshold klasifikasi optimal menggunakan Youden's Index. Model akhir kemudian diimplementasikan pada Raspberry Pi 4 untuk klasifikasi real-time—mengaktifkan buzzer bila kondisi kantuk terdeteksi dan menyinkronkan hasilnya ke cloud Supabase. Tahap terakhir adalah menyajikan hasil pemantauan dan notifikasi peringatan dini kepada pengemudi melalui aplikasi mobile SafeDrive, sekaligus menguji seluruh subsistem secara menyeluruh.

D. *Waktu dan Tempat Penelitian*

Penelitian berlangsung selama satu semester, mulai dari tahap perancangan sistem hingga pengujian dan analisis hasil. Pengujiannya sendiri dilakukan di Laboratorium I-Smile Universitas Telkom, dengan simulasi kondisi kabin truk melalui pengaturan suhu 24–26°C, getaran, dan pencahayaan.

E. *Sumber dan Perolehan Data*

Data EKG diambil dari enam sesi simulasi berkendara pada 15–18 Juni 2026, direkam menggunakan sensor AD8232 pada sampling rate 500 Hz. Enam subjek berbeda dilibatkan, masing-masing dalam dua kondisi: normal (setelah tidur cukup 7–8 jam) sebagai baseline HRV, dan lelah/mengantuk (setelah tidur kurang dari 4 jam). Kejadian kantuk—menguap, kehilangan fokus, microsleep—dicatat observer sebagai ground truth berdasarkan observasi klinis setiap menit selama sesi berlangsung.

F. *Metode Pengembangan dan Evaluasi Sistem*

Pengembangan sistem mengintegrasikan algoritma Pan-Tompkins untuk deteksi R-peak, ekstraksi fitur HRV domain waktu, dan model Random Forest yang dioptimasi melalui Grid Search serta Youden's Index. Evaluasi mencakup empat aspek: performa model Machine Learning (accuracy, recall, specificity, precision, F1-score) [28]; keandalan perangkat IoT melalui pengujian tegangan komponen; integrasi cloud database mencakup keamanan, trigger, dan sinkronisasi; serta aplikasi mobile dari sisi keandalan fungsional, performa, dan usability.

IV. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil implementasi dan pengujian sistem, mulai dari subsistem IoT, model Machine Learning, cloud database, sampai aplikasi mobile. Penyajiannya digabung antara narasi, tabel, dan gambar agar lebih mudah diikuti.

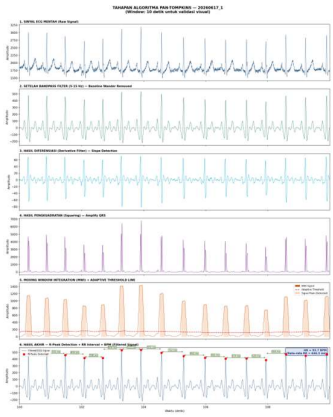
A. *Dataset dan Ekstraksi Fitur HRV*

Data EKG dari enam sesi simulasi berkendara pada 15–18 Juni 2026 direkam pada 500 Hz, mencakup kondisi Awake dan Kantuk yang dilabeli berdasarkan observasi langsung. Ringkasan tiap sesi rekaman, lengkap dengan jumlah window sebelum dan sesudah boundary removal, ditampilkan pada Tabel 1.

TABEL 1
Ringkasan Sesi Rekaman ECG

Sesi	Window	Awake	Kantuk
1	121	113	8
2	115	72	43
3	120	103	17
4	120	83	37
5	120	77	43
6	120	103	17
Sebelum boundary removal	716	551	165
Setelah boundary removal	551	472	79

Tiap window berdurasi 60 detik menghasilkan satu instance fitur HRV, melalui deteksi R-peak dengan algoritma Pan-Tompkins (Gambar 6), dilanjutkan penghitungan RR interval dan pembersihan artefak, sebelum akhirnya SDNN, RMSSD, dan pNN50 diekstraksi. Statistik deskriptif ketiga fitur tersebut pada dataset final (n=551) dirangkum pada Tabel 2.



GAMBAR 6
Tahapan Algoritma Pan-Tompkins untuk Deteksi R-Peak

TABEL 2
Statistik Deskriptif Fitur HRV

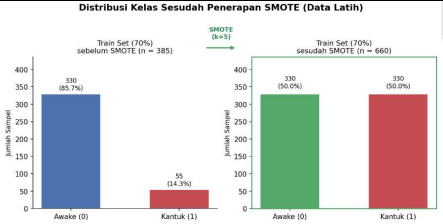
Fitur	Mean	Std	Median
SDNN (ms)	42,72	16,57	40,30
RMSSD (ms)	27,44	10,12	26,79
pNN50 (%)	7,51	7,65	5,13

B. Pembagian Data dan Penanganan Ketidakseimbangan Kelas

Dataset final berisi 551 window, dibagi menjadi data latih (70%) dan data uji (30%) melalui stratified split. Karena distribusinya timpang—472 Awake berbanding 79 Kantuk—SMOTE diterapkan pada data latih saja, sehingga jumlah sampelnya bertambah dari 385 menjadi 660. Tabel 3 merangkum perubahan ini, sedangkan Gambar 7 menunjukkan distribusi kelas secara visual sebelum dan sesudah SMOTE diterapkan. Perlu ditekankan lagi, SMOTE tidak pernah menyentuh data uji, semata untuk mencegah data leakage [15].

TABEL 3
Distribusi Data pada Tahap Training

Tahap	Awake (0)	Kantuk (1)	Total
Dataset Final	472	79	551
Train Set (70%)	330	55	385
Train Set setelah SMOTE	330	330	660



GAMBAR 7
Distribusi Kelas Sesudah Penerapan SMOTE (Data Latih)

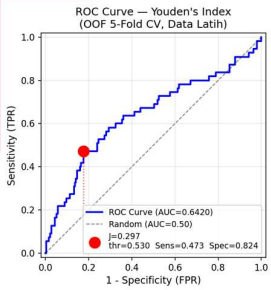
C. Optimasi Hyperparameter dan Evaluasi Model

Optimasi hyperparameter Random Forest dijalankan melalui Grid Search dengan 432 kombinasi parameter, dievaluasi memakai 5-Fold Stratified Cross Validation. Konfigurasi dengan nilai Youden's J tertinggi akhirnya dipilih sebagai model final, sebagaimana dirinci pada Tabel 4.

TABEL 4
Konfigurasi Hiperparameter Terbaik Hasil Grid Search

Parameter	Nilai
n_estimators	500
max_depth	6
min_samples_leaf	3
min_samples_split	8
class_weight	None
smote_strategy	1,0

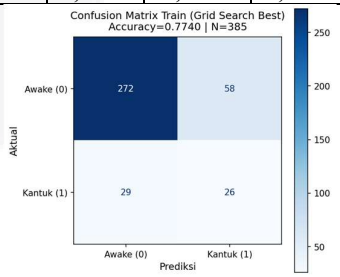
Threshold optimal yang dihasilkan Youden's Index berada di angka 0,5304, menghasilkan sensitivitas 0,4727 dan spesifisitas 0,8242 pada data latih, dengan AUC ROC 0,7391 pada evaluasi out-of-fold (Gambar 8). Performa per fold-nya sendiri—hasil 5-Fold Cross Validation pada data latih—disajikan pada Tabel 5, dan gambaran confusion matrix agregatnya ditunjukkan pada Gambar 9.



GAMBAR 8
Kurva ROC dan Penentuan Threshold Youden's Index

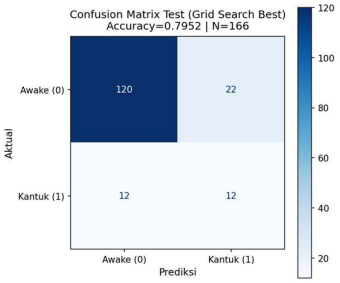
TABEL 5
Hasil 5-Fold Cross Validation

Fold	Acc.	Rec.	Spec.	Prec.	F1
1	0,8052	0,7273	0,8182	0,4000	0,5161
2	0,6883	0,2727	0,7576	0,1579	0,2000
3	0,8182	0,4545	0,8788	0,3846	0,4167
4	0,7922	0,5455	0,8333	0,3529	0,4286
5	0,7662	0,3636	0,8333	0,2667	0,3077
Mean	**0,7740**	**0,4727**	**0,8242**	**0,3124**	**0,3738**

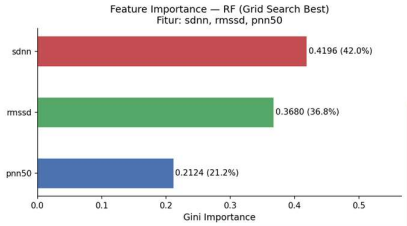


GAMBAR 9
Confusion Matrix Agregat 5-Fold Cross Validation

Setelah konfigurasi terbaik diperoleh, model akhir dilatih ulang menggunakan seluruh data latih hasil SMOTE (660 sampel), lalu diuji pada 166 sampel data uji—hasilnya divisualisasikan pada Gambar 10. Accuracy yang dicapai 79,52%, specificity 84,51%, dan recall 50%; artinya model memang lebih jago mengenali kondisi Awake dibandingkan Kantuk, konsekuensi wajar dari terbatasnya jumlah sampel kelas minoritas. Feature importance pada Gambar 11 juga menegaskan SDNN sebagai kontributor terbesar (42,0%), disusul RMSSD (36,8%) dan pNN50 (21,2%).



GAMBAR 10
Confusion Matrix Model pada Data Uji (30% Held-Out)

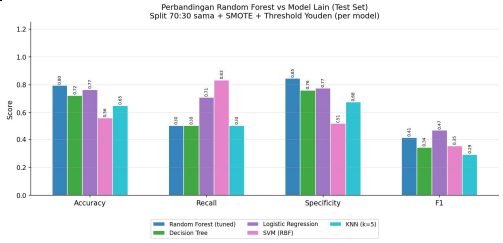


GAMBAR 11
Feature Importance Model Random Forest

Random Forest kemudian dibandingkan dengan empat algoritma lain—Decision Tree, Logistic Regression, Support Vector Machine (SVM), dan K-Nearest Neighbors (KNN)—baik melalui Tabel 6 maupun visualisasi pada Gambar 12. Random Forest unggul di accuracy dan specificity, sementara Logistic Regression justru sedikit lebih baik di recall dan F1-score. Meski begitu, Random Forest tetap dipilih sebagai model akhir karena keseimbangan performanya paling baik secara keseluruhan.

TABEL 6
Perbandingan Model Klasifikasi

Model	Acc.	Rec.	Spec.	F1	AUC
Random Forest	79,52 %	50,00 %	84,51 %	0,413 8	0,739 1
Decision Tree	72,29 %	50,00 %	76,06 %	0,342 9	0,630 3
Logistic Regressio n	76,51 %	70,83 %	77,46 %	0,465 8	0,779 9
SVM (RBF)	56,02 %	83,33 %	51,41 %	0,354 0	0,764 5
KNN (k=5)	65,06 %	50,00 %	67,61 %	0,292 7	0,636 4



GAMBAR 12
Perbandingan Random Forest dengan Model Klasifikasi Lain

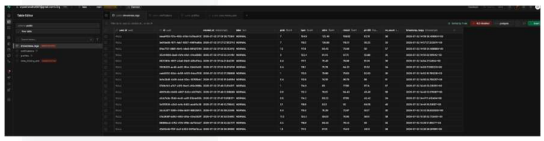
D. Hasil Pengujian Perangkat IoT dan Cloud Database

Dari sisi perangkat keras, pengujian tegangan pada 16 titik ukur komponen IoT—ESP32, AD8232, Raspberry Pi 4, buzzer, dan cooling fan menunjukkan seluruh nilainya berada dalam batas toleransi spesifikasi (status Normal), tanda catu daya sistem cukup stabil mendukung proses monitoring. Pengujian real-time terhadap 20 window data operasional pun menghasilkan accuracy dan specificity 100% tanpa satu pun missing value, mengindikasikan pipeline Machine Learning berjalan mulus di Raspberry Pi 4. Kualitas akuisisi sinyal EKG itu sendiri dapat dipantau langsung melalui antarmuka ECG Real-time Monitor pada Gambar 13, yang menampilkan pola gelombang R beserta jumlah sampel yang berhasil direkam selama proses berlangsung.



GAMBAR 13
Antarmuka ECG Real-Time Monitor selama Akuisisi Data

Sisi cloud database diuji lebih mendalam mengingat perannya yang krusial dalam sinkronisasi data. Skema basis data Supabase terdiri atas beberapa tabel utama: drowsiness_logs sebagai tempat penyimpanan hasil pemrosesan HRV label kondisi, probabilitas, BPM, SDNN, RMSSD, pNN50, beserta timestamp-nya—sebagaimana ditunjukkan pada Gambar 14, dan notifications yang mencatat riwayat peringatan setiap kali kondisi kelelahan terdeteksi (Gambar 15).



GAMBAR 14
Skema Tabel drowsiness_logs pada Supabase



GAMBAR 15
Skema Tabel notifications pada Supabase

Pengujian keamanan melalui Row Level Security (RLS) menunjukkan akses data fisiologis berhasil dibatasi hanya untuk pengguna yang terotorisasi, sementara database trigger check_drowsiness_level terbukti mampu memproses deteksi kelelahan dan mengirim notifikasi secara otomatis dari sisi backend, tanpa bergantung pada kondisi aplikasi di perangkat pengguna. Ditambah lagi, mekanisme local-cache pada Raspberry Pi menjamin tidak ada data historis yang hilang meskipun koneksi internet sempat terputus (failover capability), sehingga kontinuitas pemantauan tetap terjaga.

Pemrosesan data pada sisi Supabase juga dioptimalkan dengan memanfaatkan fitur trigger dan view bawaan PostgreSQL. Mekanisme ini memungkinkan proses deteksi kantuk, pembuatan notifikasi, dan pengolahan data riwayat berjalan otomatis langsung di sisi basis data, sehingga beban komputasi pada aplikasi berkurang dan efisiensi sistem

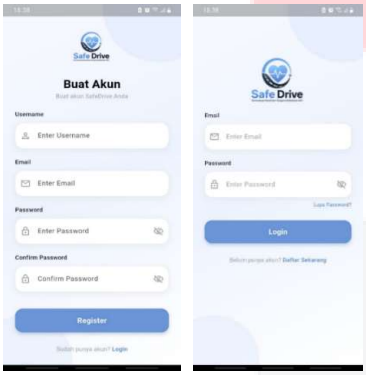
secara keseluruhan meningkat. Sinkronisasi data real-time sendiri dikonfigurasi melalui fitur PostgreSQL Realtime pada tabel drowsiness_logs dan notifications; setiap data baru dari Raspberry Pi 4 atau notifikasi hasil trigger langsung dikirim ke aplikasi SafeDrive lewat protokol WebSocket, sehingga pengemudi menerima peringatan begitu kondisi berbahaya terdeteksi, tanpa jeda yang berarti.

E. Hasil Tampilan Aplikasi

Bagian ini menjelaskan tampilan aplikasi SafeDrive yang dirancang sebagai sarana monitoring kondisi fisiologis pengemudi secara real-time.

i. Login dan Register Page

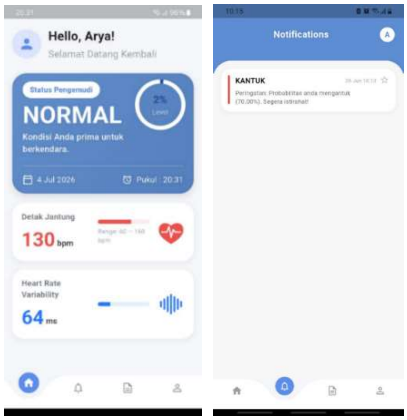
Halaman Register dan Login berfungsi sebagai fitur autentikasi pengguna yang terintegrasi dengan Supabase Authentication untuk proses pembuatan akun dan verifikasi kredensial sebelum pengguna dapat mengakses fitur utama aplikasi SafeDrive. Tampilan halaman Register dan Login ditunjukkan pada Gambar 16.



GAMBAR 16
Login dan Register

ii. Home Page dan Notification Page

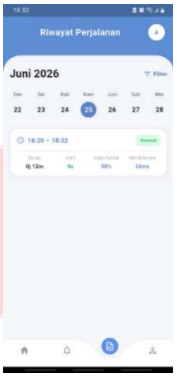
Home Page berfungsi sebagai pusat pemantauan kondisi fisiologis pengemudi secara real-time dengan menampilkan informasi berupa status pengemudi, detak jantung (BPM), nilai Heart Rate Variability (HRV), persentase kantuk, serta visualisasi sinyal ECG. Sementara itu, Notification Page berfungsi untuk menampilkan riwayat notifikasi yang dihasilkan oleh sistem sebagai informasi peringatan apabila terdeteksi kondisi waspada atau lelah pada pengemudi. Tampilan halaman ditunjukkan pada Gambar 17.



GAMBAR 17
Home Page dan Nontification Page

iii. History Page

History Page berfungsi untuk menampilkan riwayat perjalanan beserta ringkasan hasil pemantauan kondisi fisiologis pengemudi. Informasi yang ditampilkan meliputi waktu perjalanan, jumlah peringatan, tingkat kantuk maksimum, rata-rata nilai HRV, dan status pengemudi berdasarkan hasil klasifikasi. Data disimpan pada Supabase dan ditampilkan dalam bentuk daftar riwayat. Tampilan halaman History ditunjukkan pada Gambar 18.



GAMBAR 18
History Page

F. Hasil Pengujian Performa dan User Testing

Pengujian performa memakai Apptim pada dua perangkat berbeda, Redmi Pad 2 dan Samsung Galaxy A34 5G, menunjukkan penggunaan sumber daya yang relatif rendah rangkumannya ada pada Tabel 7.

TABEL 7
Hasil Pengukuran Performance Testing Aplikasi Mobile

Perangkat	Resource	Penggunaan	Penggunaan Relatif
Redmi Pad 2	CPU	143,7%	17,96%
Redmi Pad 2	RAM	479,2 MB	16,00%
Samsung A34 5G	CPU	166,7%	25,97%
Samsung A34 5G	RAM	498,3 MB	9,82%

Dari sisi fungsional, sembilan skenario keandalan sistem diuji langsung ke setiap fitur utama aplikasi, mulai dari registrasi akun sampai proses logout, sebagaimana dirangkum pada Tabel 8. Seluruh skenario tercatat berhasil tanpa satu pun kegagalan.

TABEL 8
Hasil Pengujian Keandalan Fungsional Aplikasi Mobile

Skenario Pengujian	Hasil
Registrasi akun baru	Berhasil
Login dengan akun terdaftar	Berhasil
Tampilan Dashboard real-time	Berhasil
Notifikasi peringatan kelelahan	Berhasil
Riwayat perjalanan (History)	Berhasil
Informasi akun (Profile)	Berhasil
Logout	Berhasil

Navigasi antar halaman	Berhasil
Stabilitas aplikasi (tanpa crash)	Berhasil

Survei usability terhadap tampilan, navigasi, dan kejelasan informasi turut memperoleh rating rata-rata yang sangat baik, berkisar 4,92 hingga 5,00 dari skala 5, sedangkan pengujian integrasi end-to-end yang melibatkan lima responden menunjukkan seluruh skenario—mulai dari menyalakan perangkat IoT hingga menerima notifikasi di aplikasi—berjalan berhasil tanpa kegagalan.

G. Prosedur Pengoperasian Sistem

Di lapangan, sistem dioperasikan melalui rangkaian langkah yang cukup sederhana. Raspberry Pi 4 dinyalakan terlebih dahulu sebagai pusat pemrosesan, yang secara otomatis mengaktifkan ESP32, sensor AD8232, buzzer, dan cooling fan begitu proses booting selesai. Pengemudi kemudian mengenakan wearable vest dan memasang tiga elektroda EKG pada posisi yang telah ditentukan agar sinyal jantung dapat terekam dengan baik. Raspberry Pi selanjutnya terhubung ke jaringan Wi-Fi untuk berkomunikasi dengan Supabase; apabila koneksi sempat terputus, data akan disimpan sementara dan disinkronkan otomatis setelah jaringan kembali tersedia. Begitu monitoring dimulai, sensor AD8232 merekam sinyal EKG yang diteruskan ke Raspberry Pi melalui komunikasi serial, diproses dengan algoritma Pan-Tompkins untuk deteksi R-peak, dilanjutkan ekstraksi fitur HRV, hingga akhirnya model Random Forest mengklasifikasikan kondisi pengemudi menjadi normal atau kantuk. Hasil klasifikasi beserta parameter HRV dikirim ke Supabase dan disimpan sebagai riwayat pemantauan. Apabila probabilitas kelelahan melampaui 53,04%, database trigger secara otomatis membuat data notifikasi yang dikirim melalui Supabase Realtime, buzzer pada perangkat aktif, dan notifikasi tampil di aplikasi SafeDrive; jika berada di bawah ambang batas, data tetap disimpan sebagai riwayat tanpa memicu alarm. Di sisi pengguna, pengemudi atau supervisor cukup login ke aplikasi SafeDrive menggunakan akun terdaftar untuk memantau parameter HRV, status kondisi, dan riwayat klasifikasi yang diperbarui secara berkala sepanjang perjalanan, sementara seluruh data monitoring tetap tersimpan di Supabase untuk kebutuhan riwayat dan analisis di kemudian hari.

H. Pembahasan dan Generalisasi Hasil

Secara keseluruhan, hasil pengujian memperlihatkan bahwa pendekatan berbasis HRV domain waktu cukup efektif untuk mendeteksi kelelahan pengemudi truk secara objektif, dengan akurasi yang tergolong andal (79,52%). Meski demikian, recall pada kelas Kantuk yang hanya 50% masih menjadi catatan, dan ini erat kaitannya dengan terbatasnya jumlah sampel kelas minoritas—hanya 79 dari 551 window. Yang menggembirakan, integrasi antara perangkat keras, model Machine Learning, cloud database, dan aplikasi mobile berjalan sesuai rancangan, sehingga arsitektur end-to-end IoT–Machine Learning–cloud–mobile app yang diusulkan pada penelitian ini layak dipertimbangkan untuk diterapkan lebih luas dalam pemantauan fisiologis pengemudi kendaraan berat secara real-time.

I. Potensi Pengembangan Penelitian Selanjutnya

Ke depan, penelitian ini masih terbuka untuk dikembangkan lebih jauh—melibatkan responden yang lebih banyak dan kondisi berkendara yang lebih beragam agar model memiliki kemampuan generalisasi yang lebih baik, memanfaatkan fitur HRV domain frekuensi maupun nonlinier, membandingkan dengan algoritma Machine Learning lain, hingga menambahkan sensor fisiologis pendukung seperti respirasi atau accelerometer. Fitur analisis historis pada aplikasi mobile juga bisa dikembangkan lebih lanjut, terutama untuk kebutuhan perusahaan logistik yang ingin memantau armadanya secara berkelanjutan.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem pemantauan kelelahan fisiologis pengemudi truk berbasis IoT dan Machine Learning menggunakan parameter HRV, dengan mengintegrasikan wearable EKG (AD8232, ESP32), edge computing Raspberry Pi 4 yang menjalankan algoritma Pan-Tompkins dan model Random Forest, cloud database Supabase, serta aplikasi mobile SafeDrive. Model klasifikasi yang dihasilkan mencapai akurasi 79,52%, spesifisitas 84,51%, dan recall 50% pada data uji, dengan SDNN sebagai fitur yang paling berpengaruh (42,0%). Status pencapaian pengujian pada seluruh aspek sistem dirangkum pada Tabel 9.

TABEL 9
Rangkuman Status Pencapaian Pengujian Sistem

Aspek Pengujian	Status
Akuisisi sinyal EKG (AD8232, ESP32)	Tercapai
Pemrosesan sinyal dan ekstraksi HRV (Pan-Tompkins)	Tercapai
Klasifikasi Machine Learning (Random Forest)	Tercapai
Sinkronisasi cloud database (Supabase)	Tercapai
Aplikasi mobile SafeDrive	Tercapai
Integrasi keseluruhan sistem	Tercapai

Seluruh subsistem terintegrasi dan berfungsi sesuai rancangan, sehingga sistem yang dikembangkan berpotensi menjadi teknologi pendukung keselamatan pengemudi kendaraan angkutan barang melalui pemanfaatan integrasi IoT dan Machine Learning. Untuk penelitian berikutnya, disarankan melibatkan jumlah responden yang lebih besar, kondisi berkendara yang lebih beragam, dan pengujian langsung pada kondisi operasional kendaraan di lapangan, guna mengevaluasi performa sistem pada lingkungan nyata secara lebih menyeluruh.

VI. REFERENSI

[1] S. Saleem, “Risk assessment of road traffic accidents related to sleepiness during driving: a systematic review,” Sep. 01, 2022, World Health Organization. doi: 10.26719/emhj.22.055.

[2] B. R. Truk, T. Kecelakaan, and L. Lintas, “Artikel,” 2021. [Online]. Available: www.kompas.com.

[3] J. E. Mabry et al., “Unravelling the Complexity of Irregular Shift-work, Fatigue and Sleep Health for Commercial Drivers and the Associated Implications for Roadway Safety,” Nov. 01, 2022, MDPI. doi: 10.3390/ijerph192214780.

[4] C. Zeng et al., “Driver Fatigue Detection Using Heart Rate Variability Features from 2-Minute Electrocardiogram Signals While Accounting for Sex Differences,” Sensors, vol. 24, no. 13, Jul. 2024, doi: 10.3390/s24134316.

[5] M. N. Imtiaz and N. Khan, "Pan-Tompkins++: A Robust Approach to Detect R-peaks in ECG Signals," in Proc. 2022 IEEE Int. Conf. Bioinformatics and Biomedicine (BIBM), 2022, pp. 2905–2912, doi: 10.1109/BIBM55620.2022.9995552.

[6] Y. Albadawi, M. Takruri, and M. Awad, "A Review of Recent Developments in Driver Drowsiness Detection Systems," Mar. 01, 2022, MDPI, doi: 10.3390/s22052069.

[7] T. Zambrano, L. Arias, E. Haro, V. Santos, and M. Trujillo-Guerrero, "Driver Monitoring System Using Computer Vision for Real-Time Detection of Fatigue, Distraction and Emotion via Facial Landmarks and Deep Learning," Sensors, vol. 26, no. 3, Feb. 2026, doi: 10.3390/s26030889.

[8] B. X. Wang, E. Brennand, P. Le Page, and A. R. J. Mitchell, "Heart rate variability in cardiovascular disease diagnosis, prognosis and management," Frontiers Media SA, 2026, doi: 10.3389/fcvm.2025.1680783.

[9] A. Agorastos, A. C. Mansueto, T. Hager, E. Pappi, A. Gardikioti, and O. Stiedl, "Heart Rate Variability as a Translational Dynamic Biomarker of Altered Autonomic Function in Health and Psychiatric Disease," Jun. 01, 2023, MDPI, doi: 10.3390/biomedicines11061591.

[10] M. A. Puspasari et al., "Predicting driver fatigue using HRV measures and machine learning," Front. Sports Act. Living, vol. 8, 2026, doi: 10.3389/fspor.2026.1796180.

[11] Z. Gu, V. Zarubin, and C. Martsberger, "The effectiveness of time domain and nonlinear heart rate variability metrics in ultra-short time series," Physiol. Rep., vol. 11, no. 22, Nov. 2023, doi: 10.14814/phy2.15863.

[12] F. Shaffer and J. P. Ginsberg, "An Overview of Heart Rate Variability Metrics and Norms," Sep. 28, 2017, Frontiers Media SA, doi: 10.3389/fpubh.2017.00258.

[13] A. Ganeshpurkar, V. Gupta, M. Ewomazino Akokuwebe, Y. Song, H. Wang, and H. Bi, "Optimizing public health management with predictive analytics: leveraging the power of random forest."

[14] S. Kaźmierczak and J. Mańdziuk, "Bootstrap Sampling Rate Greater than 1.0 May Improve Random Forest Performance," Oct. 2025. [Online]. Available: http://arxiv.org/abs/2410.04297

[15] D. Elreedy, A. F. Atiya, and F. Kamalov, "A theoretical distribution analysis of synthetic minority oversampling technique (SMOTE) for imbalanced learning," Mach. Learn., vol. 113, no. 7, pp. 4903–4923, Jul. 2024, doi: 10.1007/s10994-022-06296-4.

[16] D. S. Soper, "Greed is good: Rapid hyperparameter optimization and model selection using greedy k-fold cross validation," Electronics (Switzerland), vol. 10, no. 16, Aug. 2021, doi: 10.3390/electronics10161973.

[17] K. Dahal, B. Bogue-Jimenez, and A. Doblas, "Global Stress Detection Framework Combining a Reduced Set of HRV Features and Random Forest Model," Sensors, vol. 23, no. 11, Jun. 2023, doi: 10.3390/s23115220.

[18] C. S. Lin, W. T. Liu, Y. H. Chen, S. H. Lin, and C. Lin, "Artificial intelligence-enabled electrocardiography from scientific research to clinical application," Jan. 15, 2026, Springer, doi: 10.1038/s44321-025-00351-y.

[19] C. Bhattarai, S. K. Yadav, and S. Koirala, "IoT Based ECG Using AD8232 and ESP32," Nepal J. Sci. Technol., vol. 21, no. 2, pp. 115–121, Dec. 2022, doi: 10.3126/njst.v21i2.62361.

[20] M. Metshein, A. Krivšei, A. Abdullayev, P. Annus, and O. Märtens, "Non-Standard Electrode Placement Strategies for ECG Signal Acquisition," Sensors, vol. 22, no. 23, Dec. 2022, doi: 10.3390/s22239351.

[21] International Organization for Standardization and International Electrotechnical Commission, "ISO/IEC 22989:2022 — Information technology — Artificial intelligence — Artificial intelligence concepts and terminology," 2022.

[22] M. C. Bernal and Y. Molina, "A test model for database architectures: an assessment for job search engine systems," 2022. [Online]. Available: www.jart.icat.unam.mx

[23] International Organization for Standardization, "ISO 9241-11:2018 — Ergonomics of human-system interaction — Part 11: Usability: Definitions and concepts," 2018.

[24] International Organization for Standardization, "ISO 9241-210:2019 — Ergonomics of human-system interaction — Part 210: Human-centred design for interactive systems," 2019.

[25] L. Zhao, P. Li, J. Li, and C. Liu, "Influence of ectopic beats on heart rate variability analysis," Entropy, vol. 23, no. 6, Jun. 2021, doi: 10.3390/e23060648.

[26] K. Liu et al., "Driver Stress Detection Using Ultra-Short-Term HRV Analysis under Real World Driving Conditions," Entropy, vol. 25, no. 2, Feb. 2023, doi: 10.3390/e25020194.

[27] 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, Dec. 2025, doi: 10.1038/s41598-025-08582-2.

[28] H. M and S. M.N, "A Review on Evaluation Metrics for Data Classification Evaluations," Int. J. Data Mining & Knowledge Management Process, vol. 5, no. 2, pp. 01–11, Mar. 2015, doi: 10.5121/ijdkp.2015.5201.