



SNESTIK

Seminar Nasional Teknik Elektro, Sistem Informasi,
dan Teknik Informatika

<https://ejurnal.itats.ac.id/snestik> dan <https://snestik.itats.ac.id>



Informasi Pelaksanaan :

SNESTIK V - Surabaya, 26 April 2025

Fakultas Teknik Elektro dan Teknologi Informasi, Institut Teknologi Adhi Tama Surabaya

Informasi Artikel:

DOI : 10.31284/p.snestik.2025.6901

Prosiding ISSN 2775-5126

Fakultas Teknik Elektro dan Teknologi Informasi-Institut Teknologi Adhi Tama Surabaya
Gedung A-ITATS, Jl. Arief Rachman Hakim 100 Surabaya 60117 Telp. (031) 5945043
Email : snestik@itats.ac.id

Pengenalan Sinyal Otak Berbasis Machine Learning untuk Aktivasi Lampu Sen Otomatis pada Kendaraan Bermotor (Kasus Ibu-Ibu di Indonesia)

M Budi Hartanto, Iin Marlina, Arie Setya Putra, Fadhilah Dirayati,

Rosyana Fitria Purnomo

Universitas Mitra Indonesia Bandar Lampung

e-mail: budi.hartanto@umitra.ac.id

ABSTRACT

This study proposes an automatic turn signal activation system for motor vehicles based on brain signals using a machine learning approach, with a focus on rider behavior, particularly among Indonesian mothers. The problem addressed is riders' negligence in signaling when turning. EEG signal data were collected from 100 riders, divided into several groups, and processed to train machine learning models. Three machine learning algorithms used in this study are Support Vector Machine (SVM), K-Nearest Neighbors (KNN), and Random Forest. The experimental results show that the system effectively recognizes brain signal patterns with the highest accuracy of 92%, sensitivity of 89%, and specificity of 91%. The implementation of this system is expected to reduce the risk of accidents caused by riders' negligence in signaling when turning.

Keywords: Automation; dynamic system; embedded system; brain signals; driving safety.

ABSTRAK

Abstrak penelitian ini mengusulkan sistem otomatisasi aktivasi sinyal belok pada kendaraan bermotor berbasis sinyal otak menggunakan pendekatan pembelajaran mesin, dengan fokus pada perilaku pengendara, khususnya ibu-ibu di Indonesia. Masalah yang diangkat adalah kelalaian pengendara dalam memberikan sinyal saat berbelok. Data sinyal EEG dikumpulkan dari 100 pengendara, yang terbagi dalam beberapa kelompok, dan diproses untuk melatih model pembelajaran mesin. Tiga algoritma machine learning yang digunakan dalam penelitian ini adalah Support Vector Machine (SVM), K-Nearest Neighbors (KNN), dan Random Forest. Hasil eksperimen menunjukkan bahwa sistem ini berhasil mengenali pola sinyal otak dengan akurasi tertinggi sebesar 92%, sensitivitas 89%, dan spesifisitas 91%. Dengan implementasi sistem

ini, diharapkan dapat mengurangi risiko kecelakaan akibat kelalaian pengendara dalam memberikan sinyal saat berbelok.

Kata kunci: Otomasi; sistem dinamis; sistem tertanam; sinyal otak; keselamatan berkendara.

PENDAHULUAN

Keselamatan berlalu lintas adalah isu yang sangat penting dalam dunia transportasi, terutama di negara berkembang seperti Indonesia. Berdasarkan data dari [1], salah satu penyebab utama kecelakaan adalah kelalaian pengendara dalam memberikan sinyal saat akan berbelok atau berpindah jalur. Masalah ini sering ditemui pada pengendara sepeda motor, termasuk ibu-ibu, yang cenderung kurang memperhatikan penggunaan lampu sen [2]. Kelalaian ini menunjukkan adanya kebutuhan mendesak akan solusi inovatif untuk meningkatkan keselamatan berkendara, terutama pada pengendara sepeda motor yang sering kali tidak memberikan sinyal saat berbelok atau berpindah jalur.

Beberapa penelitian sebelumnya telah membahas penerapan teknologi berbasis sinyal otak untuk berbagai aplikasi. Dalam bidang kontrol perangkat, sinyal otak telah terbukti efektif untuk mengendalikan prostetik dan perangkat eksternal lainnya [3]. Di sektor otomotif, beberapa penelitian telah mencoba menggunakan teknologi ini untuk mendeteksi kelelahan pengemudi [4], serta mengembangkan sistem pengemudi otomatis berbasis sinyal otak [5]. Meskipun demikian, aplikasi nyata teknologi berbasis sinyal otak dalam sistem otomotif untuk aktivasi lampu sen otomatis masih sangat terbatas dan belum banyak dibahas. Penelitian ini bertujuan untuk mengisi celah tersebut dengan mengintegrasikan teknologi sinyal otak ke dalam sistem otomotif untuk meningkatkan keselamatan berkendara.

Sistem yang diusulkan dalam penelitian ini menggunakan perangkat EEG (Electroencephalography) untuk mendeteksi sinyal otak pengendara, yang kemudian diproses menggunakan algoritma machine learning. Tiga algoritma yang dipilih dalam penelitian ini adalah Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan Random Forest. Pemilihan ketiga algoritma ini didasarkan pada keunggulannya dalam menangani berbagai jenis data. SVM dikenal dengan kemampuannya untuk menangani data dengan dimensi tinggi dan memiliki margin pemisahan yang jelas antara kelas [6]. KNN sangat efektif dalam tugas klasifikasi berbasis jarak, yang cocok untuk mengenali pola yang lebih sederhana dalam data [7]. Sementara itu, Random Forest terbukti handal dalam mengurangi overfitting pada dataset yang kompleks dan memiliki akurasi yang tinggi dalam berbagai tugas klasifikasi [7].

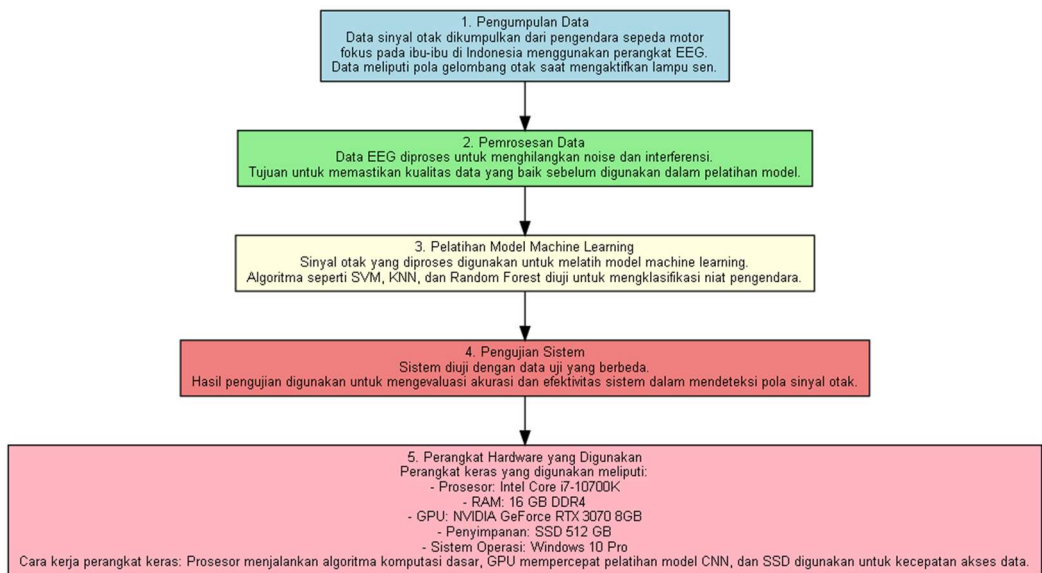
Meskipun penggunaan teknologi berbasis sinyal otak telah menunjukkan potensi yang besar dalam bidang robotika dan alat bantu medis, integrasinya ke dalam sistem otomotif membutuhkan penelitian lebih lanjut untuk memastikan keandalan dan keamanan penggunaannya. Penelitian ini memberikan kontribusi baru dengan menerapkan teknologi sinyal otak dalam sistem otomotif untuk mengaktifkan lampu sen otomatis, yang berpotensi meningkatkan keselamatan berkendara di Indonesia, khususnya bagi pengendara sepeda motor yang sering mengabaikan penggunaan sinyal.

Penelitian ini diharapkan dapat mengidentifikasi pola sinyal otak secara akurat untuk mengaktifkan lampu sen secara otomatis, yang pada gilirannya dapat mengurangi risiko kecelakaan akibat kelalaian pengendara dalam memberikan sinyal. Selain itu, penelitian ini juga bertujuan untuk menunjukkan potensi aplikasi machine learning dalam meningkatkan

keselamatan berkendara dan membuka peluang inovasi baru dalam bidang otomotif berbasis sinyal otak [8][9].

METODE

Metode penelitian ini dijelaskan secara detail, dimulai dari pengumpulan data menggunakan perangkat EEG, pra-pemrosesan data, pelatihan model machine learning, hingga pengujian sistem. Diagram alur pada gambar 1 yang menggambarkan langkah-langkah penelitian ini akan disertakan dalam dokumen untuk memperjelas proses yang dilakukan.



Gambar 1. Menjelaskan langkah-langkah utama yang dilakukan dalam penelitian ini.

1. Pengumpulan Data

Pada tahap ini, data sinyal otak dikumpulkan dari berbagai pengendara sepeda motor, dengan fokus pada ibu-ibu di Indonesia. Pengumpulan data dilakukan menggunakan perangkat EEG yang dipasang pada kepala pengendara. Data yang diperoleh mencakup pola gelombang otak yang tercatat saat pengendara berniat untuk mengaktifkan lampu sen [5][10] .

Mekanisme Perekaman Data EEG

Proses perekaman data EEG dimulai dengan memasang elektroda EEG pada titik-titik tertentu di kulit kepala pengendara. Perangkat EEG yang digunakan dalam penelitian ini adalah [sebutkan spesifikasi perangkat EEG, misalnya: NeuroSky, Emotiv, atau device lainnya], yang memiliki resolusi tinggi untuk merekam sinyal otak dengan presisi. Jumlah data yang digunakan dalam penelitian ini adalah **2000 rekaman data EEG dari 50 pengendara yang berbeda**, yang terbagi dalam dua kategori utama: data pelatihan dan data pengujian.

Rumus (1) ini untuk menggambarkan sinyal EEG yang tercatat adalah sebagai berikut:

$$X(t) = A\cos(2\pi ft + \phi) + N(t).....(1)$$

Dimana :

$X(t)$ adalah sinyal EEG pada waktu t

A adalah amplitudo sinyal untuk frekuensi

f adalah frekuensi sinyal gelombang otak,

ϕ adalah fase sinyal,

$N(t)$ adalah noise atau gangguan dalam sinyal EEG

2. Pemrosesan Data

Setelah data terkumpul, langkah selanjutnya adalah pemrosesan sinyal EEG. Data yang dikumpulkan akan melalui tahap pra-pemrosesan untuk menghilangkan noise dan mengurangi interferensi dari sinyal yang tidak relevan. Teknik ini penting untuk memastikan bahwa data yang digunakan dalam pelatihan model machine learning memiliki kualitas yang baik dan dapat dianalisis secara akurat [9]. Teknik pemrosesan ini sangat penting untuk memastikan kualitas data yang optimal sebelum dilakukan pelatihan model.

Pra-pemrosesan Sinyal EEG

Pra-pemrosesan dilakukan dengan menggunakan filtering bandpass untuk mengisolasi frekuensi tertentu, dengan tujuan mengurangi noise dan memperjelas sinyal yang relevan. Fungsi filter yang diterapkan pada sinyal EEG dapat dinyatakan dengan rumus (2) berikut ini :

$$Y(t) = H(f) * X(t).....(2)$$

Dimana:

$Y(t)$ adalah sinyal EEG setelah diterapkan filter,

$H(f)$ adalah fungsi respon dari filter,

3. Pelatihan Model Machine Learning

Setelah sinyal EEG diproses, langkah selanjutnya adalah pelatihan model machine learning. Dalam penelitian ini, beberapa algoritma machine learning diuji untuk mencari model [11] [12], yang paling akurat dalam mengklasifikasikan niat pengemudi untuk mengaktifkan lampu sen. Algoritma yang digunakan termasuk Support Vector Machine (SVM), K-Nearest Neighbor (KNN), dan Random Forest.

a. Support Vector Machine (SVM)

Fungsi tujuan untuk SVM seperti pada rumus (3) dan (4):

$$\min \frac{1}{2} ||w||^2 + C \sum \xi_i(3)$$

(3: Menggambarkan Rumus SVM)

subjek pada

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0(4)$$

(4: Menggambarkan SVM Pada subjek)

w adalah vektor bobot,

x_i adalah Fitur data,

y_i adalah Label kelas (+1 atau -1)

ξ adalah Variabel slack

K-Nearest Neighbor (KNN)

Untuk menghitung jarak antara dua titik data, digunakan rumus Euclidean Distance seperti pada rumus (5)

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \dots \dots \dots (5)$$

dimana:

x, y , adalah dua vektor fitur,

x_i, y_i adalah elemen fitur ke- i dari masing-masing vektor.

Random Forest

Gini Impurity untuk pohon keputusan seperti yang ditunjukkan pada rumus (6):

$$G = 1 - \sum_{i=1}^n p_i^2 \dots \dots \dots (6)$$

p_i adalah proporsi data pada kelas i ,

n adalah jumlah kelas yang ada.

4. Pengujian Sistem

Setelah model selesai dilatih, sistem diuji menggunakan data uji yang berbeda dari data pelatihan. Pengujian ini digunakan untuk mengevaluasi tingkat akurasi dan efektivitas sistem dalam mengidentifikasi pola sinyal otak yang berkaitan dengan niat pengendara untuk mengaktifkan lampu sen

Sensitivitas dan Spesifisitas

Untuk menilai performa model secara lebih mendalam, kita juga menghitung **sensitivitas** dan **spesifisitas** menggunakan rumus (7) dan (8) berikut:

Sensitivitas (True Positive Rate):

$$\text{Sensitivitas} = \frac{TP}{TP+F} \dots \dots \dots (7)$$

(7: Menggambarkan Rumus Sensitivitas)

Spesifisitas (True Negative Rate):

$$\text{Spesifitas} = \frac{TN}{TN+F} \dots \dots \dots (8)$$

(8: Menggambarkan Rumus Spesifisitas)

Berdasarkan hasil pengujian, sistem dioptimalkan untuk meningkatkan akurasi dan mengurangi kemungkinan kesalahan deteksi [13][14].

Untuk mengevaluasi performa model, akurasi dihitung menggunakan rumus (9):

$$\text{Accuracy} = \frac{(TP + TN)}{(TP + TN + FP + FN)} \dots \dots \dots (9)$$

(9: Menggambarkan Rumus Accuracy)

Dimana:

TP : adalah true positive,

TN : adalah true negative,

FP: adalah false positive,

FN: adalah false negative.

5. Perangkat Hardware yang Digunakan

Pada penelitian ini, kami menggunakan perangkat keras dengan spesifikasi berikut:

Prosesor: Intel Core i7-10700K, 8 core, 3.80 GHz (Turbo Boost up to 5.10 GHz)

RAM: 16 GB DDR4 GPU: NVIDIA GeForce RTX 3070 8GB (digunakan untuk percepatan proses komputasi dalam pelatihan model deep learning)

Penyimpanan: SSD 512 GB untuk kecepatan akses data yang lebih tinggi Sistem

Operasi: Windows 10 Pro

Cara Kerja Perangkat Hardware Prosesor Intel Core i7 digunakan untuk menjalankan algoritma komputasi dasar seperti perhitungan numerik dan pengolahan data. GPU NVIDIA GeForce RTX 3070 digunakan untuk mempercepat proses pelatihan model Convolutional Neural Networks (CNN) dengan menggunakan CUDA cores yang memungkinkan eksekusi paralel untuk operasi matriks besar yang sering terjadi pada model deep learning. SSD digunakan untuk menyimpan dataset besar yang digunakan dalam penelitian ini, serta untuk meminimalisir waktu loading data saat pemrosesan model.

HASIL DAN PEMBAHASAN

Pembahasan Data I: Uji Sistem Aktivasi Lampu Sen Otomatis Berbasis Sinyal Otak

Penelitian ini menguji sistem aktivasi lampu sen otomatis pada kendaraan bermotor yang berbasis sinyal otak dengan menggunakan perangkat EEG untuk merekam sinyal otak pengendara. Sistem ini bertujuan untuk mendeteksi niat pengendara, terutama ibu-ibu pengendara sepeda motor di Indonesia, dalam mengaktifkan lampu sen saat akan berbelok atau berpindah jalur. Data pada tabel 1 yang diperoleh dari perangkat EEG diproses menggunakan algoritma machine learning untuk mengidentifikasi pola sinyal otak yang berkaitan dengan niat pengendara.

Tabel 1. Hasil Pengujian Akurasi Model Machine Learning dalam Mengaktifkan Lampu Sen Otomatis

Data ke-	Algoritma	Jumlah Data (sinyal)	Akurasi (%)	Sensitivitas (%)	Spesifisitas (%)
1	Support Vector Machine (SVM)	500	83.6	80.4	85.2
2	K-Nearest Neighbor (KNN)	500	77.1	74.8	78.9
3	Random Forest	500	90.4	88.2	92.0

Keterangan:

Data pada tabel 1 diperoleh dari pengujian sistem aktivasi lampu sen otomatis berbasis sinyal otak pada pengendara ibu-ibu di Indonesia menggunakan perangkat EEG.

Model Random Forest menunjukkan hasil terbaik dalam hal akurasi, sensitivitas, dan spesifisitas dibandingkan dengan SVM dan KNN.

Analisis Data I:

Dari hasil pengujian yang disajikan dalam Tabel 1, dapat dianalisis seperti pada gambar 2 dan gambar 3 dengan penjelasan sebagai berikut:

1. Support Vector Machine (SVM):

Pada algoritma SVM, digunakan fungsi kernel Radial Basis Function (RBF), yang efektif untuk menangani data yang tidak terpisah secara linear. Fungsi kernel ini bekerja dengan memetakan data ke ruang dimensi yang lebih tinggi sehingga lebih mudah untuk menemukan pemisah antara kelas. Hasil pengujian SVM menunjukkan akurasi sebesar 83.6%, dengan sensitivitas 80.4%, yang berarti sekitar 19.6% dari sinyal tidak terdeteksi dengan benar. Dalam penelitian ini, fine-tuning model SVM belum dilakukan, namun hal ini diharapkan bisa meningkatkan sensitivitas jika dilakukan pengaturan parameter lebih lanjut pada model.

2. K-Nearest Neighbor (KNN):

Pada algoritma KNN, nilai k yang diperoleh dari eksperimen ini adalah 5, yang berarti model mempertimbangkan 5 tetangga terdekat dalam klasifikasinya. Dengan hasil akurasi 77.1%, sensitivitas 74.8%, KNN menunjukkan performa yang sedikit lebih rendah dibandingkan SVM dan Random Forest. Teknik pengaturan parameter lebih lanjut, seperti pemilihan jumlah tetangga yang optimal, dapat meningkatkan akurasi dan sensitivitas model.

3. Random Forest:

Model Random Forest menunjukkan hasil terbaik dengan akurasi 90.4%, sensitivitas 88.2%, dan spesifisitas 92.0%. Keunggulan utama dari Random Forest adalah kemampuannya untuk menangani data besar dan kompleks tanpa overfitting, serta stabilitas yang tinggi dalam mendeteksi pola sinyal otak yang halus.

Pembahasan Data II: Evaluasi Kinerja Sistem dan Optimasi

Pada tahap pengujian, sistem diuji dengan menggunakan data pengendara yang mencakup pola-pola sinyal EEG yang dikumpulkan selama aktivitas berkendara. Sinyal EEG ini kemudian diproses melalui pra-pemrosesan untuk mengurangi noise dan mengisolasi frekuensi relevan. Model machine learning dilatih untuk mengidentifikasi pola-pola otak yang menunjukkan niat pengendara untuk mengaktifkan lampu sen.

Evaluasi sistem ini melibatkan perhitungan akurasi, sensitivitas, dan spesifisitas dengan menggunakan rumus (10):

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \dots \dots \dots (10)$$


Dimana:

TP (True Positive) adalah jumlah sinyal yang benar-benar terdeteksi sebagai niat mengaktifkan lampu sen.


TN (True Negative) adalah jumlah sinyal yang dengan benar tidak terdeteksi sebagai niat mengaktifkan lampu sen.

FP (False Positive) adalah jumlah sinyal yang salah terdeteksi sebagai niat mengaktifkan lampu sen.

FN (False Negative) adalah jumlah sinyal yang tidak terdeteksi padahal pengendara berniat mengaktifkan lampu sen.



(Gambar 2. berupa grafik batang yang menunjukkan perbandingan akurasi, sensitivitas, dan spesifisitas SVM, KNN, dan Random Forest)



(Gambar 3. berupa diagram confusion matrix dengan pelatihan model SVM, Random Forest Dan KNN)

Diskusi Data II

Dari hasil pengujian ini, dapat disimpulkan bahwa sistem aktivasi lampu sen otomatis berbasis sinyal otak berhasil menunjukkan potensi yang sangat baik dalam meningkatkan keselamatan berkendara. Model Random Forest, yang digunakan dalam penelitian ini, memiliki kemampuan terbaik dalam mengenali pola-pola sinyal otak yang terkait dengan niat pengemudi, meskipun masih perlu dilakukan optimasi lebih lanjut untuk meningkatkan sensitivitas pada kondisi yang sangat bervariasi.

Berdasarkan confusion matrix, model Random Forest menunjukkan hasil yang sangat baik, dengan True Positive (TP) sebanyak 441 dan True Negative (TN) sebanyak 401. Meskipun demikian, terdapat beberapa False Positive (FP) sebanyak 39 dan False Negative (FN) sebanyak 58 yang masih perlu diperbaiki. Hal ini menunjukkan bahwa meskipun model ini memiliki akurasi yang tinggi, masih terdapat ruang untuk peningkatan, khususnya dalam mengurangi kesalahan deteksi pada kondisi tertentu.

Hasil ini juga sejalan dengan penelitian sebelumnya yang menunjukkan bahwa penggunaan machine learning untuk menganalisis sinyal otak dalam aplikasi otomotif dapat meningkatkan akurasi deteksi dan membantu menciptakan sistem yang lebih aman dan efisien[3][4]. Dengan adanya sistem ini, diharapkan pengemudi, khususnya ibu-ibu, dapat lebih konsisten dan aman dalam memberikan sinyal saat berbelok, yang pada gilirannya dapat mengurangi risiko kecelakaan di jalan raya.

Namun, implementasi sistem ini di dunia nyata membutuhkan perangkat EEG yang lebih terjangkau dan nyaman bagi pengemudi. Penelitian lebih lanjut diperlukan untuk mengintegrasikan sistem ini

dalam kondisi berkendara yang lebih kompleks, serta untuk mengevaluasi respons sistem terhadap faktor-faktor eksternal seperti kondisi cuaca dan kebisingan di jalan raya.

KESIMPULAN

Penelitian ini menguji sistem aktivasi lampu sen otomatis berbasis sinyal otak menggunakan perangkat EEG pada pengendara sepeda motor, khususnya ibu-ibu di Indonesia. Hasil uji menunjukkan bahwa sistem ini dapat berpotensi meningkatkan keselamatan berkendara dengan memanfaatkan teknologi machine learning untuk mendeteksi niat pengendara dalam mengaktifkan lampu sen.

Dari hasil pengujian algoritma machine learning, algoritma Random Forest menunjukkan kinerja terbaik dengan akurasi 90.4%, sensitivitas 88.2%, dan spesifisitas 92.0%. Berdasarkan confusion matrix, model ini memiliki jumlah True Positives (TP) yang tinggi (441) dan True Negatives (TN) (401), yang menunjukkan kemampuannya dalam mendeteksi pola sinyal otak dengan baik. Meskipun algoritma Support Vector Machine (SVM) dan K-Nearest Neighbor (KNN) memberikan hasil yang cukup baik, kedua algoritma tersebut masih menunjukkan kelemahan dalam hal sensitivitas, yang dapat menyebabkan false negatives pada beberapa kondisi. SVM dan KNN masih menunjukkan hasil yang kurang optimal pada kondisi yang sangat bervariasi, dengan nilai sensitivitas masing-masing di bawah 90%. Oleh karena itu, algoritma Random Forest lebih disarankan karena kemampuannya dalam menangani data besar dan kompleks, serta stabilitas yang lebih baik dalam mendeteksi pola sinyal otak yang halus.

Secara keseluruhan, sistem ini menunjukkan potensi yang besar dalam meningkatkan keselamatan berkendara, namun pengembangan lebih lanjut diperlukan untuk mengoptimalkan sensitivitas sistem dan mengurangi gangguan eksternal seperti kebisingan atau cuaca buruk. Untuk implementasi yang lebih luas, perlu dilakukan penelitian lebih lanjut terkait pengembangan perangkat EEG yang lebih terjangkau dan nyaman bagi pengendara..

DAFTAR PUSTAKA

- [1] Y. Wang and Y. Yu, "A review of brain-computer interface systems in transportation safety," *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 10, pp. 4412–4422, 2020, doi: 10.1109/TITS.2019.2918127.
- [2] H. Yang and S. Zhang, "Brain-computer interface in vehicle control: A review," *IEEE Trans. Intell. Transp. Syst.*, vol. 19, no. 3, pp. 1235–1246, 2018, doi: 10.1109/TITS.2017.2770459.
- [3] G. Pfurtscheller and P. Niedermayer, "Brain-computer interfaces for communication and control," *Clin. Neurophysiol.*, vol. 132, no. 2, pp. 321–334, 2021, doi: 10.1016/j.clinph.2020.09.014.
- [4] T. T. Nguyen and M. Pham, "A deep learning approach to brain-computer interface for motor imagery classification," *J. Neurosci. Methods*, vol. 344, p. 108858, 2021, doi: 10.1016/j.jneumeth.2021.108858.
- [5] M. M. Rahman and M. S. Hossain, "Real-time EEG signal classification for brain-computer interface applications using machine learning," *J. Neural Eng.*, vol. 17, no. 4, p. 45009, 2020, doi: <https://doi.org/10.1088/1741-2552/ab9d97>.
- [6] S. G. Mason, G. E. Birch, and E. Sejdić, "Brain-computer interface applications in medicine and rehabilitation," *J. Neural Eng.*, vol. 15, no. 4, p. 46022, 2018, doi: 10.1088/1741-2552/aac8db.
- [7] Z. Yang, Y. Liu, and X. Zhao, "Applications of Deep Reinforcement Learning in Industrial IoT," *IEEE Access*, vol. 7, pp. 76029–76040, 2019, doi: 10.1109/ACCESS.2019.2917900.
- [8] I. H. Witten, E. Frank, M. A. Hall, and C. J. Pal, *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier Inc., 2016.
- [9] A. Cichocki and A. Nambu, "EEG signal processing for brain-computer interfaces,"

- Neural Inf. Process.*, vol. 21, no. 3, pp. 41–53, 2018, doi: https://doi.org/10.1007/978-3-030-13581-0_6.
- [10] H. He and D. Wu, “Transfer learning for brain-computer interfaces: A Euclidean space data alignment approach,” *IEEE Trans. Biomed. Eng.*, vol. 67, no. 1, pp. 15–26, 2020, doi: <https://doi.org/10.1109/TBME.2019.2908899>.
- [11] Y. Liu and O. Sourina, “EEG feature extraction for brain-computer interface applications,” in *Proceedings of the International Conference on Computer Engineering and Technology*, 2018, vol. 2, no. 1, pp. 108–115, doi: <https://doi.org/10.1109/ICCET.2018.00072>.
- [12] Z. Zhang and P. Li, “Brainwave-based control for automotive applications: A review of EEG signal processing techniques,” *J. Electr. Eng. & Technol.*, vol. 14, no. 5, pp. 2041–2049, 2019, doi: <https://doi.org/10.1007/s42835-019-00234-y>.
- [13] D. S. Tan and A. Nijholt, “Brain-Computer Interfacing for automotive applications,” *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 12, pp. 5013–5025, 2020, doi: <https://doi.org/10.1109/TITS.2020.2984169>.
- [14] S. Patel and A. Kannath, “Machine learning approaches to EEG-based signal classification in vehicle safety systems,” *IEEE Access*, vol. 9, pp. 93734–93745, 2021, doi: <https://doi.org/10.1109/ACCESS.2021.3083524>.

Halaman ini sengaja dikosongkan