

STACKING ENSEMBLE MODEL BERBASIS SVM, RANDOM FOREST, DAN XGBOOST UNTUK KLASIFIKASI EMOSI DARI SINYAL EEG

Rafika Sani¹⁾, Sukasih²⁾, Budi Arham³⁾

^{1,2}Institut Pendidikan dan Teknologi ‘Aisyiyah Riau

³Universitas Persada Bunda Indonesia

Corresponding Author: ¹rafikasani2509@gmail.com

Article Info

Article history:

Received: Des 17, 2025

Revised: Des 25, 2025

Accepted: Jan 10, 2026

Published: Feb 01, 2026

Keywords:

Pemrosesan sinyal biomedis, Pembelajaran mesin, Pengenalan emosi, Kesehatan mental, Human-Computer Interaction.

ABSTRACT

Klasifikasi emosi berbasis sinyal EEG (Electroencephalography) merupakan bidang penting dalam pemrosesan sinyal biomedis karena perannya dalam pengambilan keputusan, interaksi sosial, dan evaluasi kondisi psikologis. Namun, tingginya dimensi data, kompleksitas pola, serta kerentanan terhadap noise menjadi tantangan utama dalam analisis EEG. Penelitian ini menerapkan Stacking Ensemble Model yang mengombinasikan Support Vector Machine (SVM), Random Forest (RF), dan XGBoost (XGB) dengan Logistic Regression sebagai meta-learner untuk meningkatkan akurasi dan stabilitas prediksi emosi. Dataset yang digunakan berasal dari Kaggle dengan 2132 data dan 2549 fitur, mencakup tiga kelas emosi: negatif, netral, dan positif. Tahapan penelitian meliputi pengecekan missing value, normalisasi menggunakan StandardScaler, encoding label, serta pembagian data menjadi data latih dan uji. Hasil eksperimen menunjukkan akurasi model tunggal yang tinggi, yaitu SVM 94,8%, RF 98,6%, dan XGB 99,5%, sedangkan model stacking mencapai akurasi 99,5% dengan nilai precision, recall, dan f1-score mendekati 1,00. Hasil ini menunjukkan bahwa stacking ensemble mampu meningkatkan keandalan klasifikasi emosi berbasis EEG dan berpotensi diterapkan pada HCI, pemantauan kesehatan mental, serta sistem pengenalan emosi real-time.



This is an open-access article distributed under the terms of the Creative Commons Attribution-NonCommercial 4.0 International (CC BY SA 4.0)

1. INTRODUCTION

Kemajuan teknologi dalam bidang machine learning dan artificial intelligence telah membuka peluang besar dalam analisis sinyal biomedis, khususnya Electroencephalography (EEG) yang digunakan untuk mempelajari aktivitas otak manusia [1]. Pengenalan emosi berbasis sinyal EEG menjadi sangat penting karena emosi berperan dalam pengambilan keputusan, interaksi sosial, dan kondisi psikologis seseorang [2]. Namun, data EEG sering memiliki dimensi tinggi, pola kompleks, dan rentan terhadap noise, sehingga memerlukan metode klasifikasi yang mampu menangkap representasi fitur secara efektif [3].

Beragam pendekatan machine learning telah diuji coba untuk mengatasi tantangan tersebut. Support Vector Machine (SVM) unggul dalam membangun margin pemisah yang optimal [4], sedangkan Random Forest (RF) menawarkan kestabilan prediksi pada data ber-dimensi tinggi melalui teknik bagging [5]. Sementara itu, XGBoost (XGB) terbukti efisien dan akurat dalam klasifikasi

data besar melalui pendekatan gradient boosting [6]. Kombinasi metode-metode ini dalam Stacking Ensemble diyakini mampu meningkatkan kinerja model dengan menggabungkan keunggulan tiap algoritma [7].

Penelitian terkini memperlihatkan efektivitas ensemble dalam klasifikasi emosi EEG. Chatterjee & Byun (2022) menerapkan stacking (RF, LightGBM, GBC) dan mencapai akurasi 99,55% [8][9]. Nandini dkk. (2025) menunjukkan bahwa ensemble LSTM-GRU pada data multimodal EEG mencapai akurasi 99,41% [8][10]. Zong dkk. (2023) memperkenalkan FCAN-XGBoost untuk klasifikasi EEG dengan akurasi 95,26%, sekaligus mengurangi kebutuhan komputasi secara signifikan [11][12].

Penelitian lain juga mendukung efektivitas ensemble. Yousefipour dkk. (2024) menggunakan arsitektur autoencoder dengan CNN dan MCCSP, meraih akurasi 99,44% dalam mengklasifikasikan emosi [13]. Lebih lanjut, laporan ulasan oleh Pillalamarri (2025) membahas pembelajaran

multimodal pada EEG untuk klasifikasi emosi, menggarisbawahi strategi fusi data yang efektif[14].

Meskipun berbagai metode dan pendekatan ensemble telah menunjukkan kinerja yang menjanjikan[15], masih terdapat permasalahan terkait konsistensi performa model pada data EEG berdimensi sangat tinggi serta potensi ketidakseimbangan kontribusi antar algoritma dasar dalam ensemble. Selain itu, sebagian penelitian lebih berfokus pada peningkatan akurasi tanpa mengkaji stabilitas prediksi antar kelas emosi maupun perilaku kesalahan klasifikasi yang terjadi. Kondisi ini menunjukkan perlunya pendekatan ensemble yang tidak hanya mengoptimalkan akurasi, tetapi juga mampu menghasilkan prediksi yang lebih stabil, seimbang, dan reliabel pada seluruh kelas emosi EEG.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan penggunaan Stacking Ensemble Model berbasis SVM, RF, dan XGB dengan Logistic Regression sebagai meta-learner untuk klasifikasi emosi EEG. Diharapkan pendekatan ini menghasilkan prediksi yang lebih akurat, stabil, dan handal. Selain itu, potensi penerapannya dalam Human Computer Interaction, pemantauan kesehatan mental, dan sistem pengenalan emosi secara real-time semakin terbuka lebar.

II. MATERIALS AND METHODS

a. Dataset

Dataset diperoleh dari Kaggle dan terdiri dari 2132 data dengan 2549 fitur sinyal EEG. Data diklasifikasikan ke dalam tiga kelas emosi, yaitu negatif (0), netral (1), dan positif (2).

b. Load Dataset

Dataset dalam format CSV dimuat ke dalam lingkungan pemrograman Python dan disimpan dalam bentuk DataFrame untuk memudahkan proses pengolahan dan analisis data.

c. Preprocessing

Tahap preprocessing meliputi pengecekan missing value, normalisasi fitur menggunakan StandardScaler, serta encoding label emosi ke dalam bentuk numerik guna memastikan data siap digunakan dalam pelatihan model.

d. Split Data

Dataset dibagi menjadi data training dan data testing dengan rasio 80:20. Data training digunakan untuk membangun model, sedangkan data testing digunakan untuk evaluasi performa.

e. Training Model Dasar

Tiga model dasar dilatih secara terpisah, yaitu Support Vector Machine (SVM), Random Forest (RF), dan XGBoost (XGB). Ketiga algoritma ini dipilih karena mampu menangani data berdimensi tinggi dan pola kompleks pada sinyal EEG.

f. Stacking Ensemble


Model stacking dibangun dengan menggabungkan prediksi dari SVM, RF, dan XGB. Logistic Regression digunakan sebagai meta-learner untuk menghasilkan prediksi akhir yang lebih stabil dan akurat.

g. Evaluasi Model

Evaluasi performa dilakukan menggunakan metrik accuracy, precision, recall, f1-score, serta confusion matrix untuk menilai kinerja model pada setiap kelas emosi.

h. Perbandingan Model


Performa model tunggal dibandingkan dengan stacking ensemble untuk mengetahui peningkatan akurasi dan konsistensi prediksi. Hasil menunjukkan bahwa stacking ensemble memberikan kinerja yang lebih baik dibandingkan model individual.



Gambar 1. Diagram Alir Penelitian

III. RESULTS AND DISCUSSION

Pada bagian ini disajikan tahapan pengujian dan hasil penelitian berdasarkan alur metodologi yang telah dijelaskan sebelumnya. Pembahasan dimulai dari penyajian data awal, proses pemuatan dataset, hingga tahapan pengolahan dan pelatihan model. Setiap tahap dijelaskan untuk menunjukkan kontribusinya terhadap hasil klasifikasi emosi berbasis sinyal EEG.



Gambar 8. Hasil Visualisasi

Gambar 8. merupakan hasil visualisasi dari konfigurasi StackingClassifier yang sudah dibangun. Bagan tersebut memperlihatkan detail setiap algoritma, termasuk parameter bawaan yang digunakan pada SVM, RF, dan XGB. Selain itu, bagan juga menegaskan bahwa Logistic Regression berperan sebagai meta-learner untuk mengintegrasikan prediksi dari ketiga model dasar menjadi keputusan akhir.

3.7. Evaluasi (accuracy, precision, recall, f1, confusion matrix)

```
# Prediksi
y_pred = stacking_model.predict(X_test)

# Evaluasi
print("Akurasi:", accuracy_score(y_test, y_pred))

y_test_lbl = le.inverse_transform(y_test)
y_pred_lbl = le.inverse_transform(y_pred)

print("\nClassification Report:")
print(classification_report(y_test_lbl, y_pred_lbl))

print("\nConfusion Matrix:")
print(confusion_matrix(y_test_lbl, y_pred_lbl))
```

Gambar 9. Evaluasi

Evaluasi dilakukan dengan menghitung akurasi, precision, recall, f1-score, dan confusion matrix. Metrik ini memberikan gambaran menyeluruh mengenai performa model, baik dari sisi ketepatan prediksi keseluruhan maupun kemampuan mengenali setiap kelas secara seimbang. Dengan evaluasi ini, dapat dilihat model mana yang memiliki performa terbaik.

Tabel 1. Clasidication Report

	Precision	Recall	f1-score	Support
0	0.99	1.00	0.99	142
1	1.00	1.00	1.00	143
2	1.00	0.99	0.99	412
Accuracy			1.00	427
Marco avg	1.00	1.00	1.00	427
Weighted avg	1.00	1.00	1.00	427

Confusion Matrix:

[[142	0	0]
[0	143	0]
[2	0	140]]

Pada tahap evaluasi, performa model diukur menggunakan metrik precision, recall, f1-score, dan accuracy, yang semuanya menunjukkan hasil mendekati sempurna dengan akurasi keseluruhan 1.00. Nilai precision, recall, dan f1-score pada setiap kategori emosi—kelas 0 (negatif), kelas 1 (netral), dan kelas 2 (positif)—berada di kisaran 0.99 hingga 1.00, menandakan tingkat kesalahan klasifikasi yang sangat rendah. Dari confusion matrix terlihat bahwa kelas 0 (negatif) dan kelas 1 (netral) diprediksi secara sempurna tanpa kesalahan, sementara pada kelas 2 (positif) hanya terdapat dua sampel yang salah terklasifikasi ke kelas 0 (negatif). Keberhasilan ini menunjukkan kemampuan model dalam membedakan pola emosi dengan konsistensi tinggi, bahkan ketika data mencakup distribusi yang beragam. Secara keseluruhan, hasil evaluasi ini menegaskan bahwa model memiliki reliabilitas yang sangat kuat serta potensi besar untuk digunakan pada aplikasi klasifikasi emosi berbasis sinyal EEG.

3.8. Bandingkan Model Tunggal vs Stacking

Perbandingan dilakukan dengan menampilkan nilai akurasi dari setiap model tunggal serta model stacking. Tabel berikut menyajikan hasil uji akurasi SVM, Random Forest, XGBoost, dan Stacking. Dengan tabel ini, pembaca dapat lebih mudah melihat performa relatif antar model.

Tabel 2. Ringkasan

Model	Akurasi
SVM	94.8%
Random Forest	98.6%
XGBoost	99.5%
Stacking	99.5%

Dari tabel terlihat bahwa SVM memiliki akurasi paling rendah yaitu 94.8%, sedangkan XGBoost dan Stacking memberikan hasil tertinggi hingga 99.5%. Random Forest menempati posisi di tengah dengan akurasi 98.6%. Hal ini membuktikan bahwa penggunaan ensemble, khususnya stacking, dapat menyamai bahkan melampaui kinerja model terbaik tunggal.

IV. CONCLUSION

Dari penelitian ini dapat disimpulkan bahwa penerapan Stacking Ensemble Model berbasis SVM, Random Forest, dan XGBoost pada klasifikasi emosi dari sinyal EEG mampu memberikan hasil yang sangat baik. Dataset berjumlah 2132 baris dan 2549 kolom dengan tiga kategori emosi berhasil diuji menggunakan model tunggal, di mana SVM memperoleh akurasi 94,8%, RF 98,6%, dan XGBoost 99,5%. Setelah digabungkan dalam model stacking dengan Logistic Regression sebagai meta-learner,

akurasi meningkat menjadi 99,5% dengan nilai precision, recall, dan f1-score berkisar antara 0,99–1,00, serta hanya terdapat 2 kesalahan klasifikasi pada kelas positif. Dengan demikian, penelitian ini dapat disimpulkan berhasil karena stacking terbukti meningkatkan stabilitas dan reliabilitas prediksi, serta berpotensi besar diterapkan pada sistem Human-Computer Interaction, pemantauan kesehatan mental, dan aplikasi real-time untuk pengenalan emosi.

ACKNOWLEDGEMENTS

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan dukungan dan bantuan selama pelaksanaan penelitian ini. Apresiasi juga disampaikan atas ketersediaan data dan sarana pendukung yang memungkinkan penelitian ini dapat dilaksanakan dengan baik. Penulis turut menghargai lingkungan akademik yang berperan dalam mendukung penyelesaian penelitian ini.

REFERENCES

- [1] R. Pillalamarri and U. Shanmugam, “A review on EEG-based multimodal learning for emotion recognition,” 2025.
- [2] M. Karthiga, E. Suganya, S. Sountharajan, and B. Balusamy, “Eeg based smart emotion recognition using meta heuristic optimization and hybrid deep learning techniques,” 2024.
- [3] D. Nandini, J. Yadav, V. Singh, V. Mohan, and S. Agarwal, “An ensemble deep learning framework for emotion recognition through wearable devices multi- modal physiological signals,” pp. 1–22, 2025.
- [4] E. Approach, “EEG-Based Emotion Classification Using Stacking Ensemble Approach,” pp. 1–15, 2022.
- [5] E. Recognition, “FCAN–XGBoost: A Novel Hybrid Model for EEG Emotion Recognition,” 2023.
- [6] B. Yousefipour, V. Rajabpour, H. Abdoljabbari, and S. Sheykhivand, “An Ensemble Deep Learning Approach for EEG-Based Emotion Recognition Using Multi-Class CSP,” 2024.
- [7] G. Obaido, O. Achilonu, and B. Ogbuokiri, “An Improved Framework for Detecting Thyroid Disease Using Filter-Based Feature Selection and Stacking Ensemble,” *IEEE Access*, vol. 12, no. May, pp. 89098–89112, 2024, doi: 10.1109/ACCESS.2024.3418974.
- [8] S. Gong *et al.*, “ENSEMBLE LEARNING MODEL FOR EEG-BASED EMOTION,” pp. 1–20.
- [9] U. Raghavendra and A. Gudigar, “A Review of Deep Learning Techniques for EEG-Based Emotion Recognition : Models , Methods , and Datasets,” pp. 1–35, 2025.
- [10] D. Learning, C. N. Network, and E. Learning, “No Title,” vol. 45, no. 4, pp. 614–622, 2019, doi: 10.14135/j.cnki.1006-3080.20180416004.
- [11] X. Shen, R. Gan, K. Wang, S. Yang, Q. Zhang, and Q. Liu, “Dynamic-Attention-based EEG State Transition Modeling for Emotion Recognition,” vol. 14, no. 8, pp. 1–14, 2015.
- [12] K. V. Kavitha, L. R. Sudha, and J. S. Jayasudha, “Results in Engineering Optimizing EEG - based Emotion Recognition with a multi-modal ensemble approach,” *Results Eng.*, vol. 26, no. April, p. 104886, 2025, doi: 10.1016/j.rineng.2025.104886.
- [13] Y. Pan, Q. Liu, Q. Liu, L. Zhang, and G. Huang, “DuA : Dual Attentive Transformer in Long-Term Continuous EEG Emotion Analysis,” pp. 1–11.
- [14] Y. Xu *et al.*, “AMDET : Attention based Multiple Dimensions EEG Transformer for Emotion Recognition,” pp. 1–10.
- [15] P. Panwar, S. Chaurasia, J. Gangrade, and A. Bilandi, “Optimizing knee osteoarthritis severity prediction on MRI images using deep stacking ensemble technique,” pp. 1–14, 2024.