

Terakreditasi SINTA Peringkat 3

Surat Keputusan Direktur Jenderal Pendidikan Tinggi, Riset, dan Teknologi Nomor 225/E/KPT/2022 masa berlaku mulai Vol.7 No. 1 tahun 2022 s.d Vol. 11 No. 2 tahun 2026

Terbit online pada laman web jurnal:
<http://publishing-widyagama.ac.id/ejournal-v2/index.php/jointecs>



Vol. 8 No. 2 (2024) 91 - 100

JOINTECS

(Journal of Information Technology and Computer Science)

e-ISSN:2541-6448

p-ISSN:2541-3619

Implementasi *Deep Learning* untuk Klasifikasi *Motor Imagery* pada Sinyal EEG

I Made Artha Agastya¹, Robert Marco², Nila Feby Puspitasari³

¹Informatika, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta

²Magister Teknik Informatika, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta

³D3 Teknik Informatika, Fakultas Ilmu Komputer, Universitas Amikom Yogyakarta

¹artha.agastya@amikom.ac.id, ²robertmarco@amikom.ac.id, ³nilafeby@amikom.ac.id

Abstract

Electroencephalography (EEG) is a technique used to record brain electrical activity through sensors placed on the scalp. Motor imagery (MI) involves the ability to imagine a movement without any external visual stimulus. The complex processing of EEG signals in MI scenarios requires advanced computational approaches to recognize the patterns that emerge during this imagery process. This study aims to compare the performance of four popular deep learning architectures namely EEGNet, EEGConformer, EEGInception, and EEGITNet in classifying EEG data within the MI context. The EEGConformer and EEGNet are the most effective models with average accuracies of 72.41% and 71.88%, respectively. Beside, EEGInception and EEGITNet recorded lower accuracies, particularly EEGInception, which lagged behind with an average accuracy of 55.59%. These findings indicate that simple architectures like EEGNet remain competitive, although more complex models like EEGConformer offer a slight performance advantage. This study also highlights the importance of subject-specific factors in enhancing model performance, which can be addressed through adaptive or personalized approaches. The results of this study are expected to provide deeper insights into the most accurate models for motor imagery EEG tasks and contribute to the development of Brain Computer Interface (BCI) applications.

Keywords: EEG; EEGNet; Motor Imagery; Deep Learning; Electroencephalography.

Abstrak

Electroencephalography (EEG) adalah teknik yang digunakan untuk merekam aktivitas listrik otak melalui sensor yang ditempatkan pada kulit kepala. Salah satu area penelitian yang menarik dalam analisis EEG adalah motor imagery (MI), yaitu kemampuan untuk membayangkan suatu gerakan tanpa adanya stimulus visual eksternal. Pengolahan sinyal EEG yang kompleks dalam skenario MI memerlukan pendekatan komputasi yang canggih untuk mengenali pola-pola yang terbentuk selama proses pembayangan tersebut. Penelitian ini bertujuan untuk membandingkan kinerja empat arsitektur deep learning populer—yaitu EEGNet, EEGConformer, EEGInception, dan EEGITNet—dalam mengklasifikasikan data EEG pada konteks motor imagery. Hasil pengujian menunjukkan bahwa EEGConformer dan EEGNet adalah model yang paling efektif, dengan akurasi rata-rata masing-masing sebesar 72,41% dan 71,88%, serta performa yang stabil di berbagai subjek. Di sisi lain, EEGInception dan EEGITNet mencatatkan akurasi yang lebih rendah, terutama EEGInception dengan akurasi rata-rata sebesar 55,59%. Temuan ini mengindikasikan bahwa arsitektur sederhana seperti EEGNet tetap kompetitif, meskipun model yang lebih kompleks seperti EEGConformer memberikan sedikit keunggulan dalam performa. Penelitian ini juga menyoroti pentingnya faktor spesifik-subjek dalam meningkatkan performa model, yang dapat diatasi melalui pendekatan adaptif atau personalisasi. Hasil penelitian ini diharapkan dapat memberikan wawasan lebih mendalam terkait model yang paling akurat dalam tugas motor imagery EEG dan berkontribusi pada pengembangan aplikasi berbasis Brain-Computer Interface (BCI).

Kata kunci: EEG; EEGNet; Motor Imagery; Deep Learning; Electroencephalography.

Diterima Redaksi : 20-08-2024 | Selesai Revisi : 28-08-2024 | Diterbitkan Online : 31-08-2024



1. Pendahuluan

Electroencephalography (EEG) [1] adalah teknik yang digunakan untuk merekam aktivitas listrik di otak melalui sensor yang ditempatkan pada kulit kepala. Salah satu bidang penelitian yang menarik dalam analisis EEG adalah motor imagery (MI), yaitu kemampuan untuk membayangkan sebuah gambar di dalam pikiran tanpa adanya stimulus visual eksternal. Pengolahan sinyal EEG yang kompleks dalam skenario motor imagery memerlukan pendekatan komputasi yang canggih untuk dapat mengenali pola-pola yang muncul selama proses pembayangan tersebut.

Dalam beberapa tahun terakhir, deep learning [2], [3] telah menjadi metode yang semakin penting dalam menganalisis data EEG karena kemampuannya untuk menangkap hubungan spasial dan temporal dari sinyal otak dengan tingkat akurasi yang tinggi. Berbagai arsitektur deep learning telah dikembangkan khusus untuk memproses data EEG, yang menawarkan pendekatan yang berbeda dalam menangani kompleksitas data tersebut. Namun, tidak semua arsitektur memberikan hasil yang seragam dalam pengenalan pola motor imagery EEG, sehingga penting untuk melakukan evaluasi terhadap kinerja berbagai model.

Dalam sebuah studi [4] yang membandingkan kinerja klasifikasi dalam-subjek untuk dataset SMR, EEGNet dan ShallowConvNet menunjukkan akurasi yang serupa dengan metode FBCSP, sementara DeepConvNet menunjukkan kinerja yang jauh lebih rendah. Untuk klasifikasi lintas-subjek pada dataset P300, MRCP, dan ERN, penelitian [4] menemukan bahwa EEGNet memiliki kinerja yang sebanding dengan model-model lain, dengan pendekatan berbasis CNN secara signifikan melampaui xDAWN pada dataset P300. Studi lain [5] menyoroti kemampuan EEGNet untuk mencapai akurasi 95,06% dengan presisi tinggi, menunjukkan efektivitasnya dalam meningkatkan sistem kontrol BCI, terutama untuk individu dengan gangguan motorik. Selain itu, penelitian [6] tentang sistem BCI gambar motorik EEG (MI) melaporkan akurasi 83% menggunakan pembelajaran mendalam, memungkinkan aplikasi seperti navigasi panorama 360 derajat yang imersif.

Dalam sebuah studi [7], model tersebut mencapai akurasi yang signifikan sebesar 95,55% pada BCI Competition III, Dataset IIIa, dan akurasi 90,18% pada BCI Competition IV, Dataset IIa. Evaluasi lain [8] menyoroti bahwa model EEG Conformer dinilai menggunakan akurasi klasifikasi dan kappa sebagai metrik utama, dengan akurasi menjadi fokus utama dalam menilai kinerjanya. Selain itu, penelitian [9] menunjukkan bahwa pendekatan Continuous Wavelet

Transform (CWT) mengungguli Short-Time Fourier Transform (STFT) dalam menganalisis sinyal EEG, dengan CWT yang dipadukan dengan Convolutional Neural Networks (CNN) menunjukkan kinerja yang sebanding atau lebih baik daripada metode lain.

Dalam sebuah studi [10], akurasi klasifikasi tertinggi sebesar 74,28% dicapai menggunakan dataset openBMI sebagai target dan GIST sebagai sumber, dengan kerangka kerja ensemble adaptasi domain dalam multi-sumber (MSDDAEF) mengungguli studi dan algoritma lain dalam klasifikasi EEG motor imagery (MI). Penelitian lain [11] tentang decoding motor imagery berbasis EEG mencapai akurasi hingga 80%, dengan pendekatan Convolutional Neural Network (CNN) menunjukkan akurasi yang lebih tinggi meskipun ada beberapa ketidakstabilan. Selain itu, EEGInception [12] menunjukkan kinerja yang sangat baik, secara signifikan melampaui lima pendekatan sebelumnya. Secara khusus, EEG-Inception meningkatkan akurasi decoding perintah sebesar 16,0%, 10,7%, 7,2%, 5,7%, dan 5,1% dibandingkan dengan rLDA, xDAWN + geometri Riemannian, CNN-BLSTM, DeepConvNet, dan EEGNet, masing-masing. Strategi pelatihan yang diusulkan juga mengurangi jumlah data kalibrasi yang diperlukan untuk model pembelajaran mendalam agar mencapai akurasi tinggi dengan subjek baru.

Dalam penelitian ini [13], dilaporkan akurasi lintas-subjek sebesar 67,32%, 82,34%, dan 81,13%, menunjukkan kinerja unggul dalam decoding sinyal motor imagery (MI) dibandingkan metode lain. Studi lain [14] mengungkapkan bahwa penggunaan Decomposition Mode Empirical berbasis Deep Neural Network (Deep-EMD) mampu meningkatkan klasifikasi MI. Metode ini secara efektif mengatasi masalah mode mixing pada komponen EEG. Selain itu, arsitektur deep semi-supervised yang independen terhadap subjek (SSDA) [15] juga terbukti lebih unggul dibandingkan metode terbaru lainnya dalam klasifikasi MI. Hasil tersebut menunjukkan bahwa meskipun hanya menggunakan sedikit sampel berlabel, kinerja klasifikasi tetap kuat.

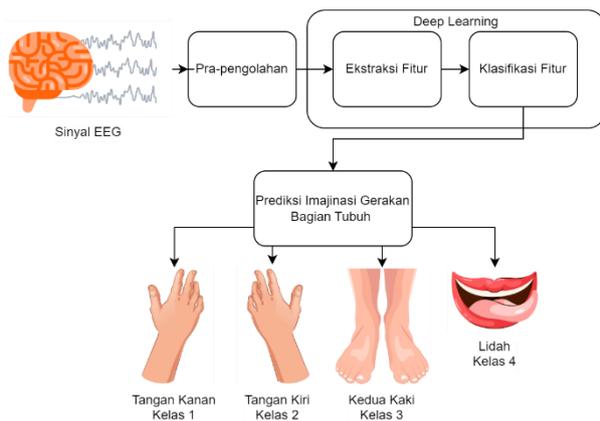
Dalam sebuah studi [16], Electroencephalography-Interpretable Temporal Network (EEG-ITNet) menunjukkan peningkatan akurasi klasifikasi hingga 5,9% dibandingkan dengan pesaingnya di berbagai skenario, dengan signifikansi statistik. Arsitektur EEG-ITNet dikenal karena kompleksitasnya yang lebih rendah dalam hal parameter yang dapat dilatih dibandingkan dengan model end-to-end lainnya seperti EEG-Inception dan EEG-TCNet. Studi lain [17] mencapai akurasi mengesankan sebesar 99,92% dan skor Kappa sebesar 0,9985. Penelitian lebih lanjut [18] memperoleh akurasi 99,7% pada dataset kelas biner dan 84% pada dataset multi-kelas. Selain itu, peneliti

[19] melaporkan akurasi terbaik sebesar 80,00% untuk dataset openBMI dan 72,73% untuk dataset GIST, mengungguli algoritma terbaru dalam klasifikasi EEG.

Saat ini masih belum ada investigasi secara menyeluruh pada arsitektur deep learning yang dibuat dengan memperhatikan karakter deep learning seperti EEGNet [4], EEGConformer [8], EEGInception [12], dan EEGITNet [16]. Penelitian ini bertujuan untuk membandingkan kinerja beberapa arsitektur deep learning tersebut dalam mengklasifikasikan data motor imagery EEG. Perbandingan ini difokuskan pada aspek akurasi untuk menentukan arsitektur yang paling sesuai dalam analisis data EEG pada konteks motor imagery. Hasil dari penelitian ini diharapkan dapat memberikan wawasan lebih dalam tentang model yang paling akurat dalam menangani tugas motor imagery EEG, serta memberikan kontribusi bagi pengembangan aplikasi berbasis Brain Computer Interface (BCI).

2. Metode Penelitian

Bab ini akan membahas secara rinci mengenai dataset yang digunakan dalam penelitian, mencakup sumber dan metode pengumpulannya. Alat-alat yang diperlukan untuk membangun dan melatih model deep learning juga akan diuraikan, mulai dari perangkat lunak hingga hardware yang digunakan. Selanjutnya, skenario pengujian yang dirancang untuk mengevaluasi performa model akan dijelaskan, termasuk metrik yang digunakan serta cara interpretasi hasil pengujian. Selain itu, ilustrasi proses implementasi klasifikasi motor imagery pada sinyal EEG ditampilkan pada Gambar 1.



Gambar 1. Klasifikasi Motor Imagery pada Sinyal EEG

2.1. Dataset

Dataset ini [20] berisi sinyal EEG yang dikumpulkan dari 9 peserta sehat. Spektrum ini meliputi 22 saluran EEG dan 3 saluran EOG dengan mastoid kiri sebagai referensi. Dataset ini adalah tugas MI dengan empat kelas, di mana kelas 1 mewakili gerakan tangan kiri, kelas 2 mewakili gerakan tangan kanan, kelas 3 mencakup gerakan kedua kaki, dan kelas 4 berhubungan dengan aktivitas lidah. Dataset ini menyertakan sampel EEG pelatihan dan validasi

individu untuk semua sembilan subjek untuk memverifikasi skema klasifikasi yang digunakan. Karena itu, tidak perlu memecah sampel data menjadi set pelatihan dan validasi menggunakan teknik cross-validation. Data direkam dari setiap peserta dalam dua sesi berbeda, dengan masing-masing sesi memiliki 6 percobaan (total 12 percobaan per peserta). Setiap percobaan terdiri dari 48 uji coba (12 untuk setiap kelas), sehingga totalnya adalah 288 uji coba dalam satu sesi. Sesi pertama digunakan sebagai data train dan sesi kedua digunakan sebagai data testing. Sehingga total data training adalah 288 sampel dan data testing terdiri dari 288 sampel.

Dataset ini direkam dengan elektroda Ag/AgCl yang dipasang dengan jarak antar-elektroda 3 sentimeter. Semua sinyal diekstraksi dengan frekuensi sampling 250Hz menggunakan filter bandpass untuk menangkap frekuensi antara 0,5 Hz hingga 100 Hz. Selama sesi, frekuensi amplifier dipertahankan pada 100µV, dan filter notch diterapkan untuk mengurangi spektrum frekuensi di bawah 20Hz. Semua data yang diproses disimpan dalam Format Data Umum (.gdf) sebagai satu file per subjek dan sesi.

2.2. Alat

Pelatihan keseluruhan dilakukan menggunakan GPU Titan V dengan memori 12 GB, yang mampu memproses 640 inti tensor. Server pelatihan dioperasikan dengan prosesor Intel generasi ke-9 9900 K yang terdiri dari 8 inti. Model pelatihan disimpan pada hard disk SSD M.2. Sedangkan pada software yang digunakan ditampilkan pada Tabel 1.

Tabel 1. Perangkat Lunak

Library	Version
scikit-learn	1.5.1
scipy	1.14.0
torch	2.4.0
braindecode	0.8.1
moabb	1.1.0
pandas	1.5.3
skorch	1.0.0

2.3. Arsitektur Deep Learning

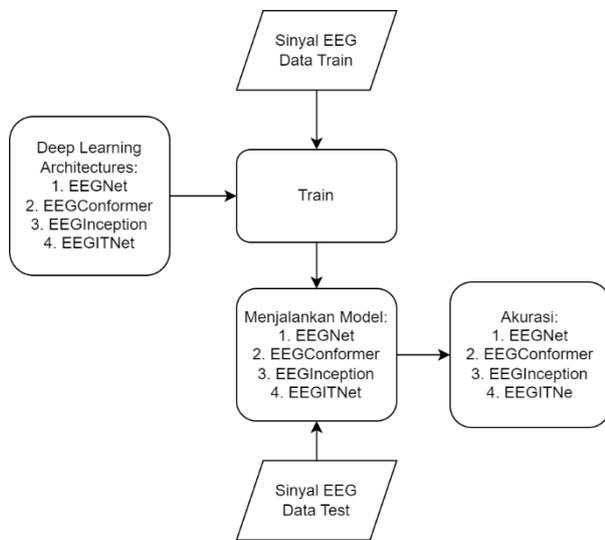
EEGNet [4] adalah arsitektur jaringan neural yang dirancang khusus untuk klasifikasi sinyal EEG (Electroencephalography). EEGNet dirancang untuk menjadi lightweight dan efisien, sehingga cocok untuk aplikasi real-time dan embedded systems. Arsitektur EEGNet terdiri dari kombinasi lapisan convolutional dan depthwise separable convolution yang dioptimalkan untuk memproses sinyal EEG dengan berbagai frekuensi dan dinamika spasial.

EEGConformer [8] adalah arsitektur berbasis Transformer yang diterapkan dalam pemrosesan sinyal EEG. EEGConformer mengintegrasikan mekanisme *self-attention* yang ada pada Transformer untuk menangkap relasi temporal dan spasial yang lebih

kompleks dalam data EEG. Arsitektur ini menawarkan keuntungan dalam menangkap pola jangka panjang yang mungkin tidak terdeteksi oleh pendekatan berbasis convolution.

EEGINception [12] adalah arsitektur yang mengadaptasi modul Inception dari model GoogleNet ke dalam domain EEG. EEGInception menggunakan kombinasi filter convolutional dengan ukuran kernel yang berbeda untuk menangkap fitur multi-skala dari sinyal EEG. Pendekatan multi-skala ini memungkinkan model untuk lebih fleksibel dalam menangani variasi frekuensi dan pola dalam sinyal EEG.

EEGITNet [16] adalah arsitektur yang dirancang untuk memberikan klasifikasi sinyal EEG yang tidak hanya akurat, tetapi juga dapat diinterpretasi dengan baik. EEGITNet menggabungkan pendekatan convolutional dengan mekanisme attention yang dirancang untuk menyoroti segmen-segmen temporal tertentu yang relevan dalam sinyal EEG. Fokus pada interpretabilitas menjadikan EEGITNet ideal untuk aplikasi di bidang klinis dan neurosains di mana keterbacaan model sangat penting.



Gambar 2. Flow chart dari Percobaan

2.4. Evaluasi Model

Akurasi adalah metrik evaluasi yang umum digunakan dalam model klasifikasi untuk menilai seberapa efektif model tersebut dalam membuat prediksi yang benar. Akurasi mengukur persentase prediksi yang benar dibandingkan dengan seluruh prediksi yang dibuat oleh model. Dalam istilah sederhana, akurasi menunjukkan seberapa banyak data yang diklasifikasikan dengan benar oleh model dari keseluruhan data yang diuji. Untuk menghitung akurasi model klasifikasi seperti pada rumus 1, pertama-tama kita harus menentukan jumlah prediksi yang benar dan jumlah total prediksi.

$$\text{Akurasi} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

Dengan True Positive (TP) adalah kasus di mana model memprediksi kelas positif dengan benar. True Negative (TN) adalah kasus di mana model memprediksi kelas negatif dengan benar. False Positive (FP) adalah kasus di mana model memprediksi kelas positif, padahal sebenarnya negatif. Dan False Negative (FN) adalah kasus di mana model memprediksi kelas negatif, padahal sebenarnya positif.

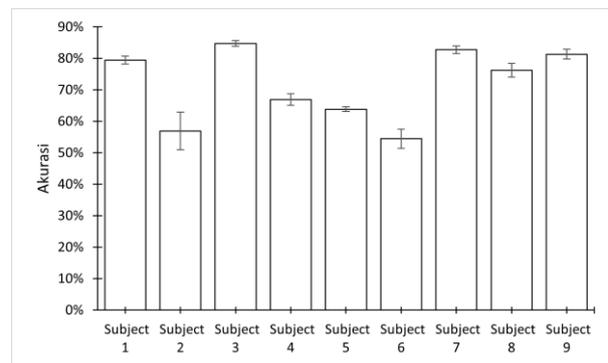
2.5. Skenario Pengujian

Seperti ditunjukkan pada Gambar 2, penelitian ini melibatkan serangkaian langkah pengujian dengan urutan yang jelas. Pertama, sinyal EEG dari data pelatihan diproses menggunakan empat arsitektur deep learning yang berbeda secara bertahap. Proses pelatihan ini menghasilkan empat model, yaitu model EEGNet, EEGConformer, EEGInception, dan EEGITNet. Setelah model-model ini terbentuk, mereka digunakan untuk memprediksi data uji. Hasil prediksi tersebut kemudian dievaluasi berdasarkan tingkat akurasi yang diperoleh.

3. Hasil dan Pembahasan

Penelitian ini mengevaluasi empat arsitektur utama, yaitu EEGNet, EEGConformer, EEGInception, dan EEGITNet. Evaluasi dilakukan dengan mengamati akurasi rata-rata serta deviasi standar sebagai indikator stabilitas performa. Pengujian ini memberikan wawasan mengenai performa berbagai model deep learning dalam menganalisis data EEG. Selain itu, analisis dilakukan terhadap data EEG dari beberapa subjek untuk memastikan konsistensi hasil.

3.1. EEGNet



Gambar 3. Hasil Pengujian Menggunakan EEGNet

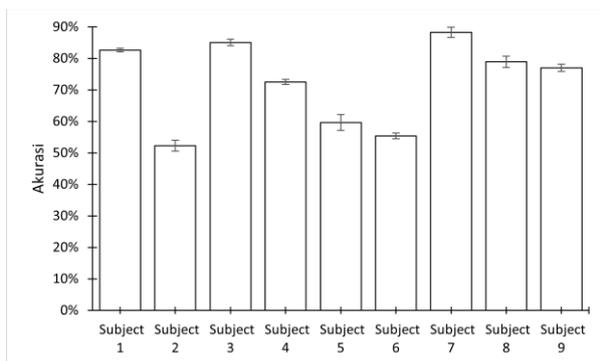
Data eksperimen mengevaluasi kinerja EEGNet pada berbagai subjek dengan hasil yang dicatat untuk lima eksperimen berbeda. Hasil analisa menunjukkan bahwa akurasi rata-rata untuk setiap subjek bervariasi dan mencerminkan konsistensi kinerja model. Sebagian besar subjek mencapai akurasi rata-rata di atas 70% meskipun ada variasi antar eksperimen seperti ditunjukkan pada Gambar 3. Lalu Subjek 3 secara konsisten menunjukkan akurasi tinggi dengan rata-rata sekitar 84,79% di semua eksperimen. Ini menunjukkan kinerja stabil dengan deviasi minimal (STD = 0,009).

Sebaliknya, Subjek 2 menunjukkan akurasi rata-rata lebih rendah sebesar 56,91% dengan deviasi standar yang lebih tinggi (STD = 0,059). Itu menunjukkan kinerja yang lebih tidak konsisten.

Hasil ini menyoroti adanya variabilitas dalam kinerja EEGNet tergantung pada subjek. Meskipun sebagian besar subjek menunjukkan akurasi yang andal, beberapa outlier seperti Subjek 2 menunjukkan derau yang tinggi dan tidak stabilnya sinyal EEG yang terekam. Klasifikasi pada Subjek 3 menunjukkan kinerja yang lebih stabil dibandingkan dengan subjek dengan variabilitas yang lebih tinggi (misalnya Subjek 2). Variasi ini menunjukkan bahwa meskipun EEGNet umumnya efektif, kalibrasi atau peningkatan yang spesifik untuk setiap subjek mungkin diperlukan untuk mencapai akurasi tinggi secara merata.

3.2. EEGConformer

Hasil dari model EEGConformer menunjukkan tingkat akurasi rata-rata yang bervariasi di antara subjek. Subjek 3 mencapai akurasi rata-rata tertinggi sebesar 85,03%, yang menunjukkan kinerja model yang kuat dan konsisten untuk subjek ini. Di sisi lain, Subjek 2 memiliki akurasi rata-rata terendah sebesar 52,29%, yang mengindikasikan bahwa efektivitas model dapat sangat bervariasi tergantung pada subjek. Nilai deviasi standar (STD) lebih lanjut mengungkapkan bahwa Subjek 1 dan Subjek 3 memiliki variabilitas yang relatif rendah dalam hasil mereka, menunjukkan kinerja model yang konsisten, sementara Subjek 5 memiliki STD yang lebih tinggi, mencerminkan inkonsistensi akurasi yang lebih besar di berbagai eksperimen seperti ditunjukkan di Gambar 4.



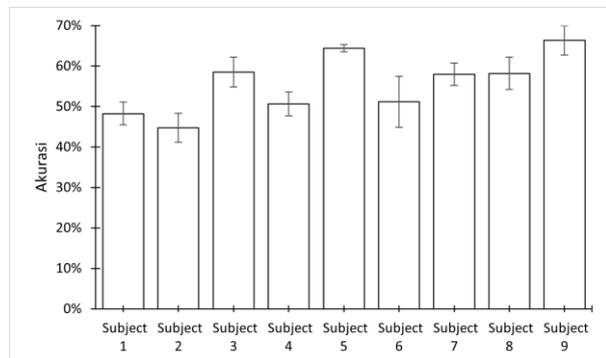
Gambar 4. Hasil Pengujian Menggunakan EEGConformer

Model EEGConformer menunjukkan kinerja yang menjanjikan untuk sebagian besar subjek, dengan akurasi rata-rata secara konsisten di atas 70% untuk tiga dari lima subjek. Akurasi tertinggi pada Subjek 3 menunjukkan ketangguhan model ketika data input selaras dengan fitur yang dipelajari oleh model. Namun, akurasi yang lebih rendah yang diamati pada Subjek 2 menunjukkan keterbatasan potensial dalam kemampuan model untuk melakukan generalisasi di berbagai subjek atau variasi sinyal. Deviasi standar yang lebih tinggi pada hasil Subjek 5 menunjukkan

ketidakstabilan yang bisa dikaitkan dengan noise spesifik subjek atau variabilitas sinyal otak. Temuan ini menyoroti pentingnya perbedaan individual ketika menerapkan model deep learning seperti EEGConformer pada data EEG. Meskipun model umumnya berkinerja baik, masih diperlukan penelitian lebih lanjut mengenai adaptasi spesifik subjek, seperti kalibrasi yang dipersonalisasi atau pendekatan hibrida yang menggabungkan pemrosesan sinyal tradisional dengan teknik deep learning.

3.3. EEGInception

Hasil dari model EEGInception menunjukkan variabilitas kinerja yang cukup mencolok di antara subjek. Subjek 5 menonjol dengan akurasi rata-rata tertinggi sebesar 64,41%, menunjukkan kinerja yang relatif baik. Sebaliknya, Subjek 1 dan 2 memiliki akurasi rata-rata di bawah 50%, yang menunjukkan bahwa model ini mengalami kesulitan untuk tampil konsisten pada individu-individu tersebut. Nilai deviasi standar (STD) mengungkapkan bahwa Subjek 5 memiliki kinerja paling stabil (STD = 0,0089), sementara Subjek 2 menunjukkan variabilitas yang lebih tinggi (STD = 0,0358), yang menandakan hasil yang kurang konsisten seperti ditunjukkan pada Gambar 5.



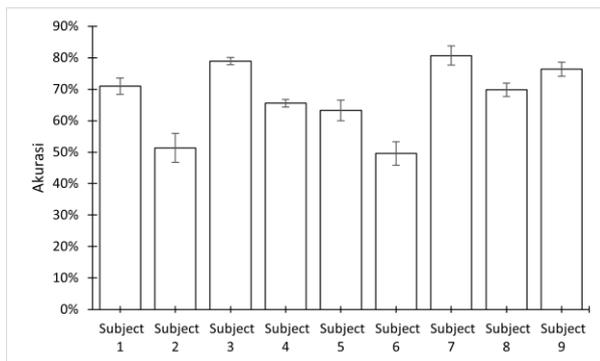
Gambar 5. Hasil Pengujian Menggunakan EEGInception

Kinerja model EEGInception menyoroti baik kekuatan maupun keterbatasannya. Meskipun model ini memberikan hasil yang cukup baik untuk beberapa subjek, terutama Subjek 5, model ini gagal mencapai akurasi tinggi secara konsisten di semua subjek. Akurasi rata-rata yang lebih rendah pada Subjek 1 dan 2 menunjukkan bahwa model ini mungkin kurang efektif dalam menghadapi jenis data EEG tertentu, yang mungkin disebabkan oleh perbedaan karakteristik sinyal atau tingkat noise yang spesifik pada subjek-subjek tersebut. Selain itu, deviasi standar yang lebih tinggi pada beberapa subjek menunjukkan ketidakstabilan dalam prediksi model, yang dapat mengurangi keandalannya. Hasil ini menunjukkan bahwa meskipun EEGInception memiliki potensi, optimisasi lebih lanjut atau penyesuaian spesifik untuk tiap subjek mungkin diperlukan agar kinerja lebih konsisten dan dapat diandalkan. Pendekatan seperti model hibrida atau penambahan data yang lebih

beragam selama pelatihan dapat dieksplorasi untuk meningkatkan generalisasi model ini di berbagai subjek.

3.4. EEGITNet

Model EEGITNet menunjukkan variasi tingkat akurasi rata-rata di antara subjek yang berbeda. Subjek 3 menonjol dengan akurasi rata-rata tertinggi sebesar 78,92%, yang menunjukkan kinerja yang konsisten dan kuat. Subjek 1 juga mencapai akurasi yang cukup baik sebesar 70,94%, meskipun dengan variabilitas yang sedikit lebih tinggi ($STD = 0,025$). Di sisi lain, Subjek 2 memiliki akurasi rata-rata sebesar 51,32%, yang secara signifikan lebih rendah dibandingkan subjek lainnya dan mencerminkan inkonsistensi kinerja yang cukup besar ($STD = 0,045$) seperti ditunjukkan pada Gambar 6.



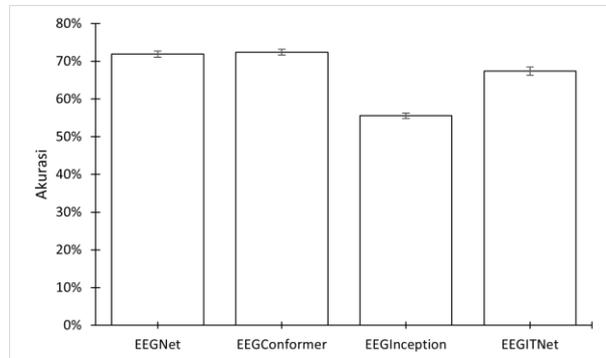
Gambar 6. Hasil Pengujian Menggunakan EEGITNet

Hasil kinerja model EEGITNet menunjukkan bahwa model ini berkinerja baik untuk beberapa subjek, terutama Subjek 3, yang memiliki akurasi rata-rata tinggi dan deviasi standar rendah ($STD = 0,011$), menandakan prediksi yang stabil dan andal. Namun, akurasi yang lebih rendah dan variabilitas yang lebih tinggi yang diamati pada Subjek 2 menunjukkan bahwa model ini mengalami kesulitan untuk melakukan generalisasi secara efektif di semua subjek. Hal ini mungkin disebabkan oleh perbedaan spesifik pada sinyal EEG, adanya noise, atau variasi lainnya yang tidak sepenuhnya dapat ditangani oleh model. Deviasi standar yang lebih tinggi pada Subjek 2 menekankan perlunya stabilitas model yang lebih baik, mungkin melalui teknik pelatihan yang lebih canggih, data tambahan, atau algoritma adaptif. Sementara itu, kinerja yang konsisten baik pada Subjek 3 menunjukkan bahwa model dapat efektif ketika data input sesuai dengan fitur yang dipelajari, yang menekankan pentingnya memahami dan mengoptimalkan kondisi di mana EEGITNet memberikan hasil terbaik.

3.5. Komparasi Hasil Pengujian Deep Learning Architecture

Perbandingan arsitektur model EEG yang berbeda mengungkapkan bahwa EEGConformer mencapai akurasi rata-rata tertinggi sebesar 72,41%, diikuti

dengan dekat oleh EEGNet dengan 71,88%. EEGITNet menunjukkan kinerja yang cukup baik dengan akurasi rata-rata 67,37%, sementara EEGInception memiliki akurasi rata-rata terendah sebesar 55,59%. Nilai deviasi standar untuk semua model relatif rendah, menunjukkan kinerja yang konsisten dalam setiap arsitektur, dengan EEGInception memiliki variabilitas terendah ($STD = 0,0073$) seperti ditunjukkan pada Gambar 7.



Gambar 7. Komparasi Hasil Pengujian Metode – Metode Deep Learning

Hasil ini menunjukkan bahwa EEGConformer dan EEGNet memberikan kinerja terbaik di antara model-model yang diuji, dengan perbedaan akurasi yang sangat kecil. Ini menunjukkan bahwa kedua arsitektur ini sangat sesuai untuk jenis data EEG yang digunakan dalam eksperimen ini. Konsistensi kinerja, seperti yang ditunjukkan oleh deviasi standar yang rendah, menunjukkan bahwa model-model ini andal di berbagai eksperimen dan subjek.

Di sisi lain, akurasi rata-rata yang lebih rendah dari EEGInception menyiratkan tantangan dalam melakukan generalisasi terhadap dataset ini. Arsitektur tersebut mungkin memerlukan optimisasi atau penyesuaian lebih lanjut untuk mencapai kinerja yang setara dengan model lain. EEGITNet, meskipun berkinerja lebih baik dari EEGInception, masih tertinggal dari EEGConformer dan EEGNet, menunjukkan bahwa mungkin ada ruang untuk perbaikan, terutama dalam menangani variasi spesifik subjek pada data.

Analisis arsitektur model EEG yang berbeda menunjukkan bahwa EEGConformer dan EEGNet memberikan hasil yang paling konsisten dan akurat, dengan akurasi rata-rata masing-masing sebesar 72,41% dan 71,88%. Model-model ini unggul dalam stabilitas dan kemampuan generalisasi antar subjek, menjadikannya pilihan yang andal untuk analisis data EEG. Di sisi lain, EEGInception tertinggal dengan akurasi rata-rata sebesar 55,59%, menunjukkan bahwa arsitektur ini mungkin memerlukan optimisasi yang signifikan agar dapat bersaing dengan model lainnya. EEGITNet, dengan akurasi rata-rata 67,37%, menawarkan kinerja yang moderat namun masih dapat ditingkatkan untuk lebih baik menangani variasi spesifik subjek.

Secara keseluruhan, temuan ini menekankan bahwa EEGConformer dan EEGNet adalah model yang paling sesuai untuk aplikasi luas yang memerlukan kekokohan dan keandalan. Sementara itu, EEGInception dan EEGITNet memiliki potensi tetapi memerlukan penyetelan lebih lanjut untuk sepenuhnya mengoptimalkan kapabilitasnya. Studi ini juga menyoroti pentingnya mempertimbangkan adaptasi spesifik subjek dan menyeimbangkan kompleksitas model dengan kinerja, karena model yang lebih sederhana seperti EEGNet masih memberikan hasil yang kompetitif dengan tuntutan komputasi yang lebih rendah. Pada akhirnya, pemilihan model yang tepat tergantung pada kebutuhan spesifik aplikasi, apakah itu dalam hal akurasi, generalisasi, atau efisiensi.

3.6. Komparasi dengan Peneliti Terdahulu

Kinerja berbagai algoritma klasifikasi EEG, seperti yang dirangkum dalam Tabel 2, mencerminkan kemajuan signifikan dalam bidang ini. Metode CSP+LCD dari tahun 2019 mencapai akurasi sebesar 79,7%, yang menunjukkan baseline yang solid untuk klasifikasi EEG. Namun, metode ini telah dilampaui oleh teknik-teknik terbaru. Misalnya, algoritma NWFE+OvO+TSD dari tahun 2020 memperbaiki akurasi tersebut menjadi 82,7%, menunjukkan kemajuan dalam ekstraksi fitur dan strategi klasifikasi. Kemajuan lebih lanjut terlihat pada metode MEMD+SVM yang diperkenalkan pada tahun 2021, yang mencapai akurasi sebesar 85,4%. Peningkatan ini menegaskan efektivitas menggabungkan teknik dekomposisi multi-skala dengan pengklasifikasi yang kuat. Metode terbaru, FBCSP+CNN dari tahun 2024, merupakan puncak dari kinerja klasifikasi EEG saat ini, dengan mencapai akurasi yang mengesankan sebesar 89,3%. Kesuksesan FBCSP+CNN menyoroti manfaat mengintegrasikan Filter Bank CSP dengan Jaringan Saraf Konvolusi, yang cakup dalam mempelajari pola kompleks dalam data EEG.

Tabel 2. Komparasi Performa Algoritma Dengan Peneliti Terdahulu

Referensi	Tahun	Algoritma	Akurasi
[21]	2019	CSP+LCD	79.7
[22]	2020	NWFE+OvO+TSD	82.7
[23]	2021	MEMD+SVM	85.4
[24]	2024	FBCSP+CNN	89.3
Penulis	2024	EEGConformer	72,4

Sebagai perbandingan, EEGConformer sebagai metode terbaik yang diinvestigasi dari tahun 2024, yang mencapai akurasi sebesar 72,4%, masih kalah dari metode terbaru. Beberapa faktor dapat berkontribusi pada perbedaan ini. Kompleksitas algoritma EEGConformer, potensi masalah dalam penanganan data, dan detail implementasi spesifik semuanya dapat mempengaruhi kinerjanya. Untuk mengatasi masalah ini, beberapa langkah disarankan. Optimalisasi model EEGConformer dan hiper-parameternya sangat penting untuk meningkatkan kinerja. Selain itu,

mengintegrasikan elemen sukses dari metode lain, seperti menggabungkan EEGConformer dengan teknik ekstraksi fitur canggih seperti FBCSP atau meningkatkan arsitekturnya dengan aspek CNN, dapat meningkatkan akurasi. Memperluas validasi EEGConformer di berbagai dataset dan kondisi juga dapat membantu mengidentifikasi dan mengatasi keterbatasannya saat ini. Meskipun metode EEGConformer menunjukkan potensi akurasi yang tinggi, saat ini kinerjanya belum setara dengan teknik-teknik yang paling maju.

4. Kesimpulan

Studi ini membandingkan kinerja empat arsitektur model EEG: EEGNet, EEGConformer, EEGInception, dan EEGITNet. Hasilnya menunjukkan bahwa EEGConformer dan EEGNet merupakan model yang paling efektif, dengan akurasi rata-rata tinggi masing-masing sebesar 72,41% dan 71,88%, serta kinerja yang stabil di berbagai subjek. Kedua model ini menunjukkan kemampuan generalisasi yang kuat, menjadikannya pilihan yang andal untuk berbagai aplikasi EEG. Di sisi lain, EEGInception dan EEGITNet menunjukkan akurasi yang lebih rendah, dengan EEGInception secara khusus berkinerja kurang baik dibandingkan model lainnya. Temuan ini menunjukkan bahwa meskipun arsitektur yang lebih sederhana seperti EEGNet tetap sangat kompetitif, model yang lebih kompleks seperti EEGConformer menawarkan sedikit keunggulan dalam kinerja. Studi ini juga menekankan pentingnya faktor spesifik subjek, yang dapat diatasi melalui pendekatan adaptif atau yang dipersonalisasi.

Penelitian di masa depan sebaiknya berfokus pada optimisasi model dengan kinerja lebih rendah seperti EEGInception dan EEGITNet untuk meningkatkan akurasi dan konsistensinya. Ini dapat mencakup penyetelan hiperparameter, penambahan data pelatihan, atau eksperimen dengan model hibrida yang menggabungkan kekuatan dari berbagai arsitektur. Selain itu, eksplorasi algoritma adaptif yang menyesuaikan model dengan karakteristik spesifik subjek dapat meningkatkan akurasi keseluruhan dan mengurangi variabilitas kinerja. Penelitian lanjutan juga dapat mengeksplorasi cara mengurangi beban komputasi pada model kompleks seperti EEGConformer sambil mempertahankan akurasi tinggi. Terakhir, evaluasi model-model ini pada dataset yang lebih beragam dan dalam aplikasi dunia nyata akan memberikan wawasan lebih dalam tentang kemampuan generalisasi dan efektivitas praktisnya.

Ucapan Terimakasih

Penelitian ini telah menerima dukungan dari Universitas Amikom Yogyakarta dalam bentuk hibah penelitian dasar.

Daftar Pustaka

- [1] X. Gu *et al.*, “EEG-Based Brain-Computer Interfaces (BCIs): A Survey of Recent Studies on Signal Sensing Technologies and Computational Intelligence Approaches and Their Applications,” *IEEE/ACM Trans. Comput. Biol. Bioinforma.*, vol. 18, no. 5, pp. 1645–1666, 2021, doi: 10.1109/TCBB.2021.3052811.
- [2] H. Altaheri *et al.*, “Deep Learning Techniques For Classification Of Electroencephalogram (EEG) Motor Imagery (MI) Signals: A Review,” *Neural Comput. Appl.*, vol. 35, no. 20, pp. 14681–14722, 2023, doi: 10.1007/s00521-021-06352-5.
- [3] A. Al-Saegh, S. A. Dawwd, and J. M. Abdul-Jabbar, “Deep Learning For Motor Imagery EEG-Based Classification: A Review,” *Biomed. Signal Process. Control*, vol. 63, no. October 2020, p. 102172, 2021, doi: 10.1016/j.bspc.2020.102172.
- [4] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. Lance, “EEGNet: A Compact Convolutional Neural Network For EEG-Based Brain-Computer Interfaces,” *J. Neural Eng.*, vol. 15, no. 5, pp. 1–30, 2018, doi: 10.1088/1741-2552/aace8c.
- [5] A. Kumari *et al.*, “EEG-Based Motor Imagery Channel Selection And Classification Using Hybrid Optimization And Two-Tier Deep Learning,” *J. Neurosci. Methods*, vol. 409, p. 110215, Sep. 2024, doi: 10.1016/j.jneumeth.2024.110215.
- [6] F. E. Ekpar, “A Baseline Electroencephalography Motor Imagery Brain-Computer Interface System Using Artificial Intelligence and Deep Learning,” *Eur. J. Electr. Eng. Comput. Sci.*, vol. 8, no. 3, pp. 46–53, Jun. 2024, doi: 10.24018/ejece.2024.8.3.632.
- [7] M. Kaur, R. Upadhyay, and V. Kumar, “A Hybrid Deep Learning Framework Using Scaling-Basis Chirplet Transform for Motor Imagery EEG Recognition in Brain–Computer Interface Applications,” *Int. J. Imaging Syst. Technol.*, vol. 34, no. 4, Jul. 2024, doi: 10.1002/ima.23127.
- [8] Y. Song, Q. Zheng, B. Liu, and X. Gao, “EEG Conformer: Convolutional Transformer for EEG Decoding and Visualization,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 31, pp. 710–719, 2023, doi: 10.1109/TNSRE.2022.3230250.
- [9] B. Rahma, R. Aicha, and M. Kamel, “Classification of Motor Imagery EEG Signals Using Deep Learning,” in *2024 2nd International Conference on Electrical Engineering and Automatic Control (ICEEAC)*, May 2024, pp. 1–5, doi: 10.1109/ICEEAC61226.2024.10576444.
- [10] M. Miao, Z. Yang, Z. Sheng, B. Xu, W. Zhang, and X. Cheng, “Multi-Source Deep Domain Adaptation Ensemble Framework For Cross-Dataset Motor Imagery EEG Transfer Learning,” *Physiol. Meas.*, vol. 45, no. 5, p. 055024, May 2024, doi: 10.1088/1361-6579/ad4e95.
- [11] J. V. Juan, R. Martínez, E. Iáñez, M. Ortiz, J. Tornero, and J. M. Azorín, “Exploring EEG-Based Motor Imagery Decoding: A Dual Approach Using Spatial Features And Spectro-Spatial Deep Learning Model IFNet,” *Front. Neuroinform.*, vol. 18, Feb. 2024, doi: 10.3389/fninf.2024.1345425.
- [12] E. Santamaria-Vazquez, V. Martinez-Cagigal, F. Vaquerizo-Villar, and R. Hornero, “EEG-Inception: A Novel Deep Convolutional Neural Network for Assistive ERP-Based Brain-Computer Interfaces,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 28, no. 12, pp. 2773–2782, 2020, doi: 10.1109/TNSRE.2020.3048106.
- [13] W. Li *et al.*, “Self-Supervised Contrastive Learning For EEG-Based Cross-Subject Motor Imagery Recognition,” *J. Neural Eng.*, vol. 21, no. 2, p. 026038, Apr. 2024, doi: 10.1088/1741-2552/ad3986.
- [14] H. Yu, S. Baek, J. Lee, I. Sohn, B. Hwang, and C. Park, “Deep Neural Network-based Empirical Mode Decomposition for Motor Imagery EEG Classification,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, pp. 1–1, 2024, doi: 10.1109/TNSRE.2024.3432102.
- [15] S. Sartipi and M. Cetin, “Subject-Independent Deep Architecture for EEG-based Motor Imagery Classification,” *IEEE Trans. Neural Syst. Rehabil. Eng.*, pp. 1–1, 2024, doi: 10.1109/TNSRE.2024.3360194.
- [16] A. Salami, J. Andreu-Perez, and H. Gillmeister, “EEG-ITNet: An Explainable Inception Temporal Convolutional Network for Motor Imagery Classification,” *IEEE Access*, vol. 10, pp. 36672–36685, 2022, doi: 10.1109/ACCESS.2022.3161489.
- [17] N. E. H. S. Ben Aissa, A. Lakas, A. Korichi, C. A. Kerrache, and A. N. Belkacem, “Robust Detection of Adversarial Attacks for EEG-based Motor Imagery Classification using Hierarchical Deep Learning,” in *2023 15th International Conference on Innovations in Information Technology (IIT)*, Nov. 2023, pp. 156–161, doi: 10.1109/IIT59782.2023.10366492.
- [18] N. Sharma, A. Upadhyay, M. Sharma, and A. Singhal, “Deep Temporal Networks For EEG-Based Motor Imagery Recognition,” *Sci. Rep.*, vol. 13, no. 1, p. 18813, Nov. 2023, doi: 10.1038/s41598-023-41653-w.

- [19] M. Miao, Z. Yang, H. Zeng, W. Zhang, B. Xu, and W. Hu, "Explainable Cross-Task Adaptive Transfer Learning For Motor Imagery EEG Classification," *J. Neural Eng.*, vol. 20, no. 6, p. 066021, Dec. 2023, doi: 10.1088/1741-2552/ad0c61.
- [20] C. Brunner, R. Leeb, and G. Müller-Putz, "BCI Competition 2008 - Graz Data Set A." IEEE Dataport, 2008, doi: 10.21227/katb-zv89.
- [21] Q. Ai *et al.*, "Feature Extraction Of Four-Class Motor Imagery EEG Signals Based On Functional Brain Network," *J. Neural Eng.*, vol. 16, no. 2, pp. 1–16, 2019, doi: 10.1088/1741-2552/ab0328.
- [22] A. Wijaya, T. B. Adji, and N. A. Setiawan, "Improving Multi-Class EEG-Motor Imagery Classification Using Two-Stage Detection On One-Versus-One Approach," *Commun. Sci. Technol.*, vol. 5, no. 2, pp. 85–92, 2020, doi: 10.21924/cst.5.2.2020.216.
- [23] A. Tiwari and A. Chaturvedi, "A Novel Channel Selection Method For BCI Classification Using Dynamic Channel Relevance," *IEEE Access*, vol. 9, pp. 126698–126716, 2021, doi: 10.1109/ACCESS.2021.3110882.
- [24] R. Bhambare and M. Jain, "Multi-Class Motor Imagery Detection Using Optimum Channels," *Int. J. Intell. Syst. Appl. Eng.*, vol. 12, no. 13, pp. 67–78, 2024.

Halaman ini sengaja dikosongkan