

Klasifikasi Gerakan Jari Menggunakan Elektroensefalogram (EEG) Berbasis Deep Evolving Denoising Autoencoder (DEV DAN)

Widhi Winata Sakti^{1*}, Siti Tsaniyatul Miratis Sulthoniyah¹, Sutikno²

¹Teknik Elektronika, Universitas PGRI Banyuwangi

¹Teknologi Hasil Perikanan, Universitas PGRI Banyuwangi

²Teknik Elektro, Universitas Muhammadiyah Jember

Universitas PGRI Banyuwangi, jalan Ikan Tongkol No 22 Kertosari, Banyuwangi, Indonesia

Universitas Muhammadiyah Jember, Jl. Karimata No. 49 Jember 68121 Jawa Timur

E-mail: widhiwinatas@unibabwi.ac.id

Naskah Masuk: 16 September 2025; Diterima: 23 Februari 2026; Terbit: 31 Maret 2026

ABSTRAK

Abstrak - Penyandang disabilitas sering menghadapi keterbatasan dalam berinteraksi dengan lingkungan, sehingga diperlukan teknologi berbasis *brain-computer interface* (BCI) yang mampu menerjemahkan sinyal otak menjadi perintah. Sinyal *elektroensefalogram* (EEG) yang digunakan dalam BCI bersifat kompleks, *non stasioner*, dan rentan terhadap *noise*, sehingga menyulitkan proses klasifikasi pola aktivitas otak. Penelitian ini merumuskan masalah bagaimana meningkatkan akurasi dan efisiensi klasifikasi EEG dengan tetap mempertahankan informasi dominan dari sinyal. Kebaruan penelitian terletak pada penerapan algoritma *Deep Evolving Denoising Autoencoder* (Devdan) yang dipadukan dengan *pipeline* pemrosesan komprehensif, meliputi *filter Notch* dan *Bandpass* (7–13 Hz), *windowing*, *standard scaling*, serta reduksi dimensi menggunakan *Principal Component Analysis* (PCA). Integrasi ini memungkinkan Devdan bekerja lebih optimal dengan data yang lebih bersih dan tereduksi. Hasil pengujian menunjukkan rata-rata akurasi klasifikasi 96,13% dengan loss 0,83 dan waktu pelatihan singkat 2,05 detik. Algoritma Devdan terbukti adaptif terhadap variasi responden dengan hasil konsisten dan stabil. Temuan ini menunjukkan bahwa pendekatan yang diusulkan efektif untuk klasifikasi EEG secara *real time* dan berpotensi mendukung pengembangan teknologi BCI bagi penyandang disabilitas dalam komunikasi maupun kontrol perangkat.

Kata kunci: EEG, Devdan, PCA, klasifikasi, disabilitas

ABSTRACT

Abstract - Persons with disabilities often face limitations in interacting with their environment, thereby requiring brain-computer interface (BCI) technology capable of translating brain signals into commands. Electroencephalogram (EEG) signals used in BCI are complex, non-stationary, and highly susceptible to noise, making the classification of brain activity patterns challenging. This study addresses the problem of improving the accuracy and efficiency of EEG classification while preserving the dominant information within the signals. The novelty of this research lies in the application of the Deep Evolving Denoising Autoencoder (Devdan) algorithm integrated with a comprehensive preprocessing pipeline, including Notch and Bandpass (7–13 Hz) filtering, windowing, standard scaling, and dimensionality reduction using Principal Component Analysis (PCA). This integration enables Devdan to operate more effectively on cleaner and reduced data. Experimental results demonstrate an average classification accuracy of 96.13%, with a loss of 0.83 and a short training time of 2.05 seconds. Devdan proved to be adaptive to variations among respondents with consistent and stable outcomes. These findings indicate that the proposed approach is effective for real-time EEG classification and has strong potential to support the development of BCI technology for persons with disabilities in communication and device control.

Keywords: EEG, Devdan, PCA, classification, disability.

Copyright © 2026 Jurnal Teknik Elektro dan Komputasi (ELKOM)

1. PENDAHULUAN

Amputasi adalah kondisi medis di mana sebagian atau seluruh anggota tubuh terputus akibat cedera, penyakit [1][2]. Menurut organisasi kesehatan dunia *World Health Organization* (WHO), amputasi merupakan masalah kesehatan global yang signifikan dengan dampak besar terhadap fungsi fisik, psikologis, dan kualitas hidup individu. Data WHO menunjukkan bahwa sekitar 85% dari amputasi terjadi

di negara berkembang, termasuk Indonesia [3], disebabkan oleh komplikasi *diabetes mellitus*, infeksi, trauma kecelakaan, dan penyakit *vaskular perifer*. Amputasi tidak hanya menyebabkan kehilangan fungsi motorik, tetapi juga menimbulkan dampak sosial dan ekonomi yang besar, baik bagi individu maupun masyarakat luas. Hal ini memperkuat pentingnya pengembangan teknologi rehabilitasi, termasuk prostetik moderen yang dapat meningkatkan kualitas hidup penyandang amputasi [4].

Rehabilitasi penderita amputasi tangan dengan penggunaan tangan prostesis moderen kini semakin maju dengan dukungan teknologi neuroteknologi seperti elektroensefalografi (EEG) [5]. EEG merupakan sinyal listrik yang dihasilkan oleh aktivitas otak dan dapat digunakan untuk mengontrol tangan prostesis secara intuitif melalui sistem *brain computer interface* (BCI) [6]. Tangan prostesis dapat dikendalikan sesuai dengan keinginan pengguna, seperti melakukan gerakan menggenggam atau membuka tangan, sehingga meningkatkan fungsi dan kualitas hidup penderita amputasi. Berbagai penelitian telah mengintegrasikan teknologi EEG dengan kecerdasan buatan (AI) untuk meningkatkan akurasi prediksi gerakan tangan prostetik secara *real time* [7].

Sinyal EEG cenderung memiliki tingkat *noise* dan artefak yang tinggi, seperti gangguan dari kelopak mata bergerak, otot wajah, dan lingkungan listrik sekitar, sehingga memerlukan pemrosesan sinyal yang kompleks agar data yang diperoleh akurat dan dapat diandalkan [8][9]. Berbagai studi melaporkan akurasi klasifikasi yang berbeda-beda tergantung pada metode diantaranya model CNN berhasil mencapai akurasi hingga sekitar 95.45% untuk klasifikasi dua jenis gerakan tangan buka dan genggam [10], klasifikasi lima gerakan tangan menggunakan *Artificial Neural Network* (ANN) mencapai akurasi sekitar 80% [11], dan studi lain dengan model *FusionNet* untuk klasifikasi data lintas subjek dan intra subjek melaporkan akurasi hingga 87.1% pada masing-masing responden [12]. Variabilitas sinyal EEG antar individu cukup besar, sehingga model yang dikembangkan pada satu orang belum tentu bekerja optimal pada orang lain tanpa pelatihan ulang yang intensif dan personalisasi sistem [13].

Solusi EEG menggunakan *incremental learning* dapat difokuskan pada metode pembelajaran yang adaptif dalam mengklasifikasikan sinyal EEG secara bertahap seiring bertambahnya data baru [14]. Keunikan *incremental learning* ini cocok untuk menangani perubahan sinyal EEG dari subjek yang berbeda atau perubahan kondisi sepanjang waktu, serta untuk memperbaiki performa model sewaktu-waktu dengan data tambahan [15]. Pada penelitian ini diajukan pendekatan model *Deep Evolving Denoising Autoencoder* (DEV DAN), sistem ini memiliki mekanisme *incremental learning* dan menggunakan fase pelatihan berpasangan generatif dan diskriminatif, selain itu evolusi struktural yang terjadi pada kedua fase memungkinkan adaptasi terhadap perubahan data. Sehingga menghasilkan akurasi ideal dalam klasifikasi [15].

2. KAJIAN PUSTAKA



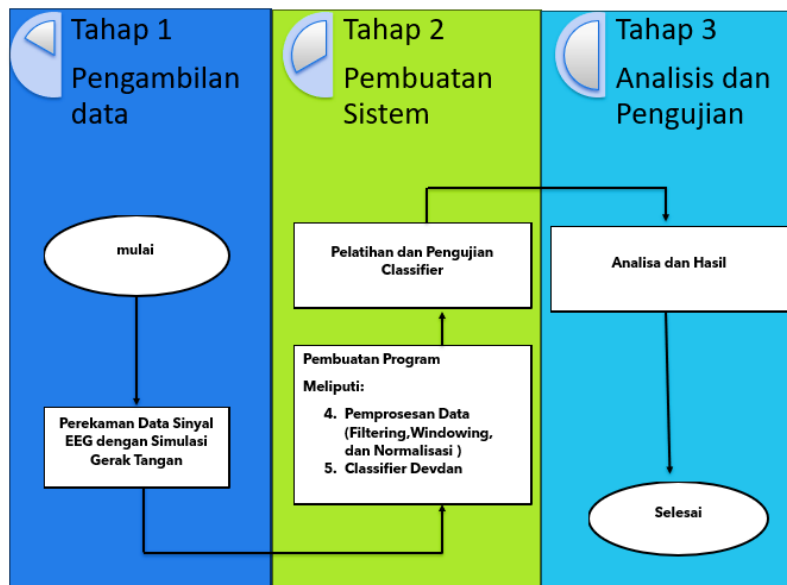
Gambar 1. Penelitian *elektroensefalogram* (EEG)

Pada gambar 1 sinyal suara dan otot memiliki kelemahan terhadap kebutuhan disabilitas [16]. Sinyal otak dari EEG menawarkan lebih banyak fleksibilitas untuk mengatasi keterbatasan tersebut dengan mengolah stimulus dari sinyal otak sehingga tidak memerlukan aksi motorik [17]. Berdasarkan pertimbangan tersebut penelitian ini berfokus pada penggunaan sinyal EEG. Pada penelitian sebelumnya model yang umum digunakan Adalah *Artificial Neural Network* (ANN) dan *Support Vector Machine* (SVM) model ini masih menggunakan pengaturan manual pada jaringan *Neural* [18][19][20][21]. Hal ini menjadi permasalahan yang mendasar pada variabilitas respons individu untuk mendapatkan model adaptif, maka dari itu diajukan pembaruan menggunakan *Deep evolving denoising autoencoder* (DEV DAN). Permodelan DEV DAN memiliki mekanisme adaptif untuk meningkatkan memiliki mekanisme fase pelatihan berpasangan generatif dan diskriminatif. Evolusi struktural yang terjadi pada kedua fase memungkinkan adaptasi terhadap perubahan data. Sehingga menghasilkan akurasi ideal dalam klasifikasi. Sehingga model DEV DAN akan lebih adaptif dan dapat meningkatkan akurasi pada klasifikasi.

DEV DAN adalah metode pembelajaran *incremental* berbasis *Denoising Autoencoder* (DAE) yang dikembangkan untuk analisis data streaming yang terus berkembang (*evolving data streams*). DEV DAN memiliki struktur jaringan yang dinamis dan terbuka (*open structure*), yang memungkinkan penambahan dan penghapusan unit tersembunyi (*hidden units*) secara otomatis sesuai kebutuhan selama proses pembelajaran berlangsung.

3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif yang menekankan pada langkah perbaikan dan pembaruan metode. Pada penelitian sebelumnya *Deep evolving denoising autoencoder* (DEV DAN) hanya diujikan pada *Benchmarking* sistem atau hanya pada data berbentuk fitur gambar dan data tabular, serta belum diujikan kepada data sinyal EEG.




Gambar 2. Diagram alir penelitian

Gambar 2 merupakan alur tahapan penelitian EEG untuk kontrol prostetik tangan berbasis Brain-Computer Interface (BCI), yang terdiri dari tiga tahap utama. Tahap 1 pengambilan data tahap awal, dilakukan pencarian referensi penelitian yang relevan sebagai dasar teori dan metode. Selanjutnya dilakukan perekaman data sinyal EEG menggunakan simulasi gerak tangan sebagai data mentah penelitian. Tahap 2 pembuatan system, tahap ini berfokus pada pengembangan program yang meliputi pemrosesan data (seperti *filtering*, *windowing*, dan normalisasi), serta penerapan *classifier* Devdan. Hasil program kemudian digunakan untuk pelatihan dan pengujian *classifier* guna mengklasifikasikan sinyal EEG. Tahap 3 analisis dan pengujian, tahap terakhir meliputi analisis hasil pengujian sistem menggunakan *confusion matrix* dan grafik *accuracy*

3.1 Data Sinyal EEG

Pada Penelitian ini digunakan dataset jurnal *A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces* dengan tipe EEG-1200 JE-921A yang sering digunakan pada peralatan rumah sakit. Sinyal diukur dengan 38 chanel input [22].

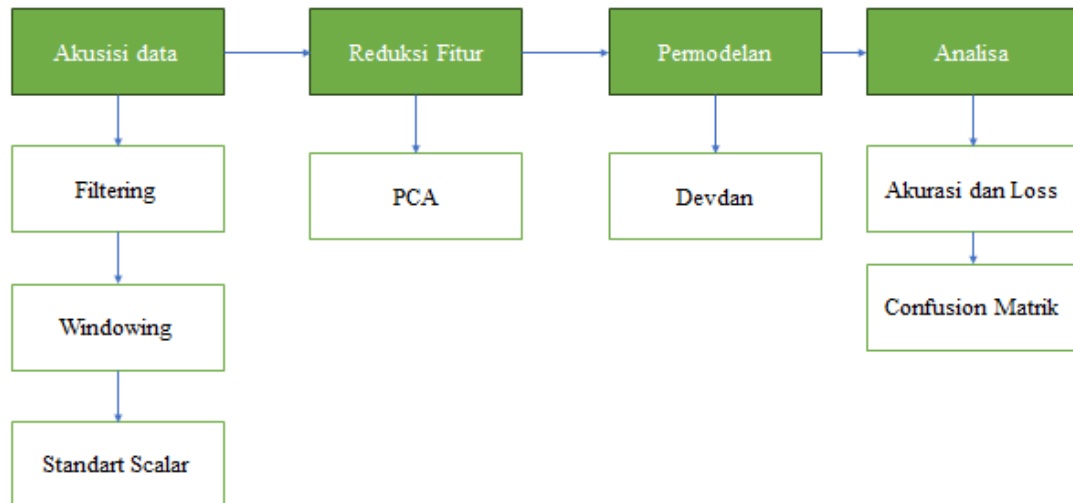


Gambar 3. Prosedur perekaman elektroensefalogram

Pada gambar 3 prosedur akuisisi dan pemrosesan data disajikan kepada peserta berupa respon gambar yang pada tampilan. Sinyal *elektroensefalogram* (EEG) pada peralihan gambar direkam oleh perangkat keras EEG-1200 dan disimpan melalui perangkat lunak perekam *Neurofax*. Setelah percobaan, data EEG yang diperoleh disimpan dan diekspor sebagai file ASCII untuk diproses lebih lanjut. File data ASCII diimpor ke Matlab untuk dianalisis.

3.2 Pembuatan Sistem Klasifikasi *Deep Evolving Denoising Autoencoder* (DEV DAN)

Pengolahan sinyal EEG ditekankan pada metode pengolahan fitur data, pada bagian ini fitur divisualisasikan menggunakan *Brain Computer Interface* (BCI) untuk mengetahui pergerakan data pada tampilan sinyal.




Gambar 4. Pembuatan sistem klasifikasi *Deep evolving denoising autoencoder*

Pada gambar 4 menunjukkan alur proses pengolahan sinyal EEG untuk klasifikasi menggunakan metode *Deep evolving denoising autoencoder* (DEV DAN), yang terdiri dari 4 tahap utama:

3.3 Akuisi Data

Proses *Filtering elektroensefalogram* (EEG) adalah proses penting dalam pengolahan sinyal EEG yang bertujuan untuk menghilangkan gangguan dan artefak dari sinyal mentah agar sinyal yang dihasilkan dapat dianalisis dengan lebih akurat.



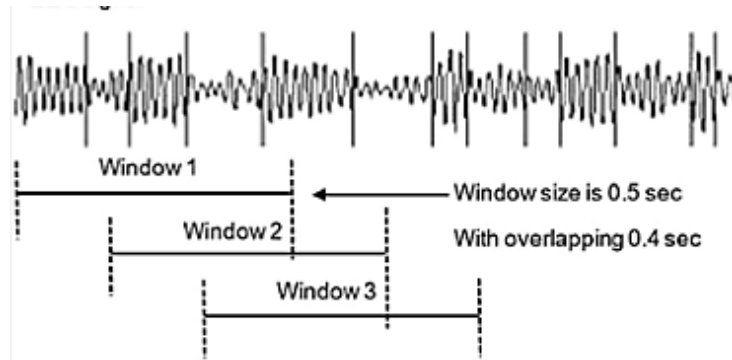
Gambar 5. Rentang filter sinyal *elektroensefalogram*

Pada gambar 5 menunjukkan contoh gelombang EEG dengan beberapa jenis gelombang otak yang berbeda, diukur dalam frekuensi *Hertz* (Hz), serta variasi bentuk gelombang selama satu detik waktu pengukuran. Gelombang *Beta* (12-30 Hz) muncul saat otak dalam keadaan aktif, waspada, atau fokus memproses informasi, gelombang *Alpha* (8-12 Hz), sering muncul saat otak dalam keadaan *rileks* tapi sadar, misalnya saat santai dengan mata tertutup, gelombang *Theta* (4-8 Hz) terkait dengan keadaan

mengantuk, meditasi, atau tahap awal tidur ringan, gelombang *Delta* (1-4 Hz) Muncul saat tidur nyenyak atau kondisi kesadaran sangat rendah.

3.3.1 Windowing Data

Proses *windowing* adalah tahap penting dalam pengolahan sinyal EEG yang bertujuan untuk membagi data sinyal kontinu menjadi potongan-potongan waktu yang lebih kecil dan terdefinisi, yang disebut jendela (*window*).




Gambar 6. *Windowing*

Pada gambar 6 Setiap *windowing* dianalisis secara terpisah untuk mengekstrak fitur atau informasi yang relevan. Pada penelitian ini digunakan *window* dibuat dengan tumpang tindih (*overlap*) antar jendela untuk menjaga kontinuitas dan menghindari hilangnya informasi transisi penting dengan rentang data 200 data *persampling*.

3.3.2 Standart Scaler

Proses *Standart Scaler* adalah tahap normalisasi data yang dilakukan setelah *windowing* pada sinyal EEG. Tujuannya adalah untuk mengubah nilai fitur data agar memiliki skala yang seragam, sehingga memudahkan proses pelatihan model dan meningkatkan performa klasifikasi.




Gambar 7. *Standart scalar*

Pada gambar 7 bagian kiri menunjukkan distribusi original data dari masing-masing kolom dengan sebaran dan pusat yang berbeda-beda. Setiap garis mewakili satu kolom, di mana posisi puncak dan lebar kurva menggambarkan karakteristik data aslinya. Grafik bagian kanan menunjukkan distribusi data yang telah dinormalisasi. Semua kolom memiliki sebaran dan puncak yang hampir serupa dan terpusat di nol dengan lebar yang setara. Hasil ini menunjukkan bahwa proses normalisasi berhasil menyamakan skala dan posisi data dari setiap kolom.

3.3.3 Reduksi Fitur Principal Component Analysis (PCA)

Reduksi fitur adalah tahap dalam pengolahan data EEG yang bertujuan untuk mengurangi jumlah fitur atau variabel yang akan dianalisis, dengan mempertahankan informasi penting sebanyak mungkin. Tujuan utamanya adalah mengurangi kompleksitas data, mempercepat proses komputasi, serta meningkatkan performa algoritma klasifikasi.

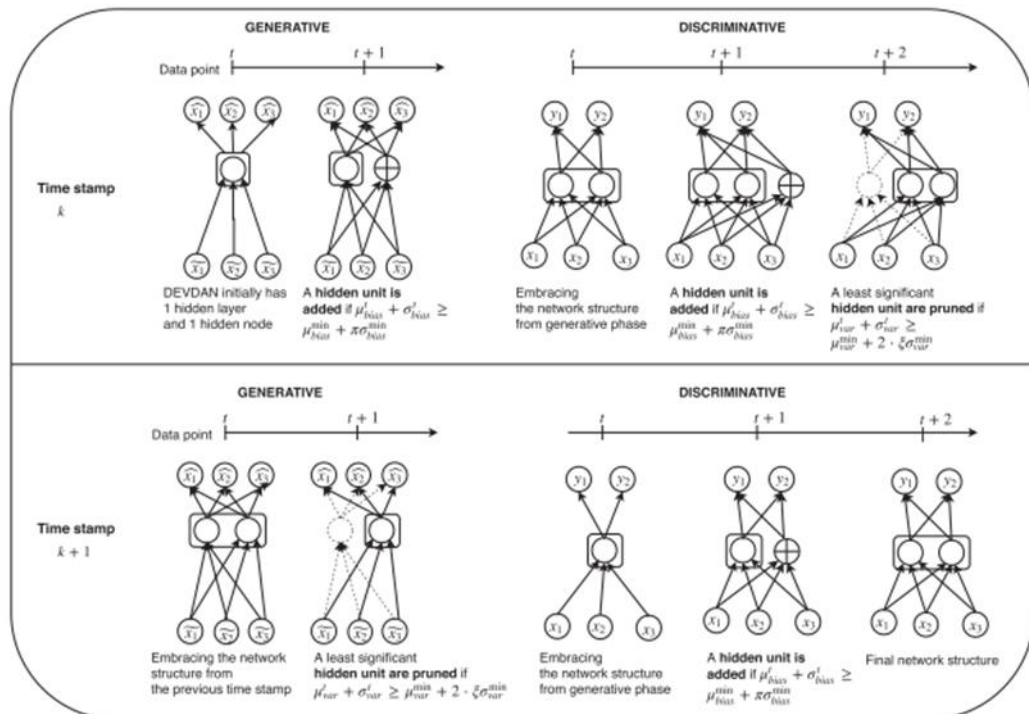


Gambar 8. *Principal component analysis*

Pada Gambar 8 adalah ilustrasi dari *Principal Component Analysis (PCA)*, sebuah teknik reduksi dimensi yang digunakan dalam analisis data multivariat. Sumbu X dan Y merepresentasikan dua variabel asli dalam ruang fitur. Titik-titik hitam adalah data observasi. PC1 (*Principal Component 1*) dan PC2 (*Principal Component 2*) adalah dua komponen utama hasil transformasi PCA. PC1 adalah arah dengan varian (penyebaran data) terbesar. PCA memilih arah ini karena mengandung informasi terbanyak dari data. PC2 tegak lurus (*ortogonal*) terhadap PC1 dan menangkap varian terbesar kedua sehingga data lebih mudah dianalisis dalam dimensi yang lebih sedikit, sambil tetap mempertahankan informasi sebanyak mungkin dalam bentuk varian.

3.4 Permodelan

Klasifikasi metode *Deep Evolving Denoising Autoencoder (DEV DAN)* dimulai dengan pembagian data *training* dan *test* sebesar 80% dan 20%, pengujian dilakukan pada data test 20% untuk mendapatkan metrik performa seperti akurasi, presisi, dan *recall*. Pembagian 80 dan 20 ini umum digunakan untuk menjaga keseimbangan antara pembelajaran model yang maksimal dan evaluasi performa generalisasi yang realistis.



Gambar 9. Algoritma *Deep evolving denoising autoencoder*

Pada gambar 9 menunjukkan metode *Deep Evolving Denoising Autoencoder (DEV DAN)* ini bekerja dalam dua fase terkoordinasi:

Fase Generatif (unsupervised): Melatih DAE untuk merekonstruksi input dari data yang telah dirusak sebagian (*masking noise*), sehingga dapat mengekstraksi fitur yang lebih robust dan menanggulangi *noise*. Fase ini juga dapat berjalan meskipun tanpa label kelas (*unlabeled data*).

$$W, b, c = \arg \min_{W, b, c} \sum_{t=1}^T \frac{1}{T} L(X_t, z_t) \quad (1)$$

$$L(X_t, z_t) = \frac{1}{2} \sum_{t=1}^T (X_t - z_t)^2 \quad (2)$$

Dimana X_t adalah vektor masukan bebas noise dan z_t adalah vektor masukan yang dibangun kembali. T adalah jumlah sampel yang diamati sejauh ini. Metode SGD digunakan dalam skenario pembelajaran parameter untuk memperbarui W, b, c . Turunan orde pertama dalam metode SGD dihitung terhadap batasan bobot terikat $W = W^T$. Perhatikan bahwa langkah penyesuaian parameter dilakukan dalam jaringan dinamis yang dimulai dengan hanya satu fitur masukan $R = 1$ dan mengembangkan struktur jaringannya sesuai permintaan.

Fase Diskriminatif (supervised): Setelah label tersedia, jaringan ditambah lapisan *softmax* untuk klasifikasi. Model dilatih menggunakan data berlabel untuk meningkatkan akurasi klasifikasi.

$$W, b, \Theta, \eta = \arg \min_{W, b, \Theta, \eta} \sum_{t=1}^T \frac{1}{T} L(C_t, \hat{C}_t) \quad (3)$$

Dimana $L(C_t, \hat{C}_t)$ adalah fungsi kerugian *entropi* silang. Proses penyesuaian dilakukan dengan cara pembelajaran *one pass* dan proses adaptasi per sampel. Skenario pembelajaran struktural juga terjadi pada kelompok diskriminatif. Fase pelatihan asli di mana metode NS dapat dirumuskan sehubungan dengan kesalahan prediksi kuadrat daripada kesalahan rekonstruksi. Derivasi serupa diterapkan di sini namun perbedaannya hanya terdapat pada ekspresi keluaran model diskriminatif sebagai $s(X_t W + b) + \eta$ skema pengkodean dan penguraian kode.

DEVDAN mengatasi tantangan konsep drift (perubahan distribusi data) dengan mengatur penambahan (*growing*) dan pengurangan (*pruning*) neuron tersembunyi berdasarkan analisis bias dan varians dari rekonstruksi dan prediksi model menggunakan rumus *Network Significance* (NS). Sistem pembelajaran ini juga berjalan secara *single-pass learning*, artinya data hanya diproses sekali, cocok untuk *streaming* dan data besar yang terus mengalir.

$$MSE = \sum_{t=1}^T \frac{1}{T} (X_t - z_t)^2 \quad (4)$$

Dimana $(X_t - z_t)$ masing-masing mewakili variabel masukan bersih dan fitur masukan DAE yang dibangun kembali. Rumus ini mengalami dua hambatan untuk skenario pembelajaran sekali jalan.

3.5 Analisa

akurasi dan *loss* pada umumnya menitikberatkan pada pentingnya memonitor kedua metrik tersebut secara bersamaan dalam pelatihan model. Akurasi memberikan gambaran hasil akhir klasifikasi secara ringkas, sementara *loss* memberikan pemahaman mendalam tentang proses optimisasi *mode* akurasi dan *loss*

3.5.1 Akurasi dan loss

Akurasi adalah metrik yang digunakan untuk mengukur performa model klasifikasi, biasanya dinyatakan dalam persentase. Akurasi menghitung proporsi prediksi yang benar terhadap seluruh prediksi, sehingga menggambarkan seberapa baik model mampu mengklasifikasikan data secara tepat. Akurasi mudah diinterpretasikan dan sering dipantau selama proses pelatihan model untuk melihat peningkatan performa [23].

Loss merupakan fungsi biaya yang mengukur selisih antara nilai prediksi model dengan nilai kebenaran (*ground truth*). Nilai *loss* memberikan gambaran seberapa jauh prediksi dari target yang diharapkan dan biasanya tidak dinyatakan dalam persentase, melainkan berupa nilai numerik yang dicoba diminimalkan sepanjang proses pelatihan. Fungsi *loss* umum termasuk *log loss*, *cross-entropy*, dan *mean squared error*. *Loss* menjadi panduan bagi algoritma optimisasi dalam mengupdate parameter model agar kesalahan prediksi berkurang dan akurasi meningkat [24].

3.5.2 Confusion Matrix

Confusion matrix adalah sebuah tabel yang digunakan untuk mengevaluasi performa model klasifikasi dengan membandingkan prediksi model terhadap label sebenarnya. Matriks ini menunjukkan

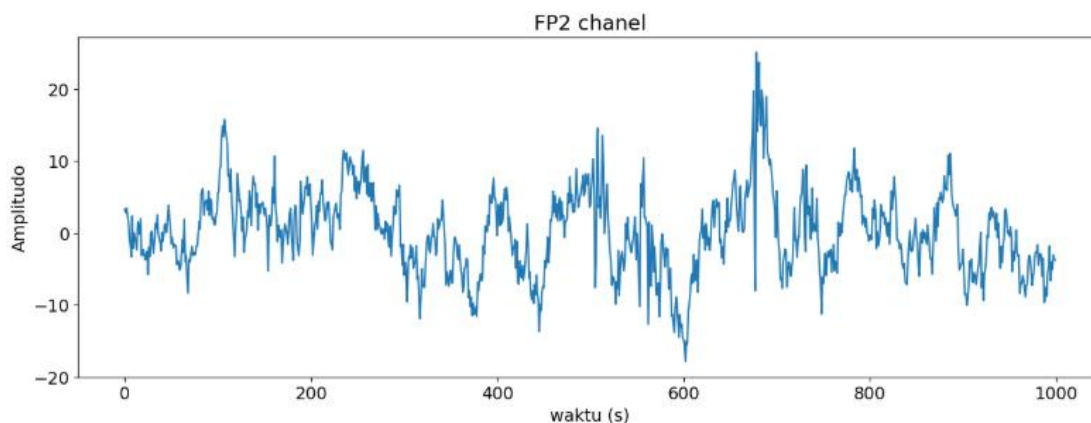
jumlah prediksi benar dan salah yang dibagi ke dalam empat kategori utama: *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN) [25].

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{(TN + FP)}$
		Precision $\frac{TP}{(TP + FP)}$	Negative Predictive Value $\frac{TN}{(TN + FN)}$	Accuracy $\frac{TP + TN}{(TP + TN + FP + FN)}$

Gambar 10. *Confusion matrix*

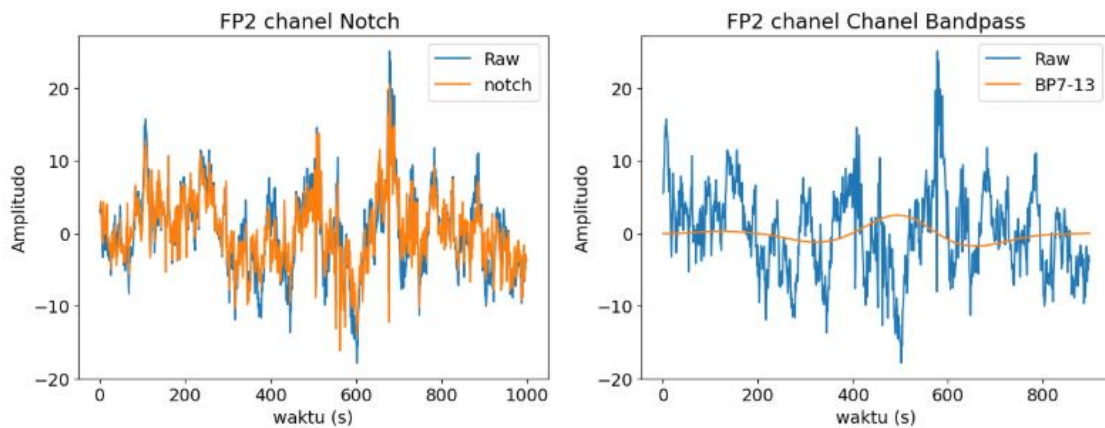
Pada gambar 10 adalah representasi dari *confusion matrix*, yang merupakan alat evaluasi utama untuk model klasifikasi dalam *deep learning* maupun pembelajaran mesin secara umum. *True Positive* (TP) adalah model memprediksi positif dan kenyataannya memang positif. *False Negative* (FN) model memprediksi negatif padahal seharusnya positif. *False Positive* (FP) model memprediksi positif padahal sebenarnya negatif. *True Negative* (TN) model memprediksi negatif, dan kenyataannya juga negatif. *Sensitivity* adalah mengukur seberapa baik model mengenali data positif yang sebenarnya. *Specificity* mengukur seberapa baik model mengenali data negatif yang sebenarnya. *Precision* mengukur ketepatan model dalam memprediksi kelas positif. *Negative Predictive Value* (NPV) mengukur ketepatan model dalam memprediksi kelas negatif. *Accuracy* mengukur total proporsi prediksi yang benar oleh model.

4. HASIL DAN PEMBAHASAN



Gambar 11. Sinyal mentah *Elektroensefalogram*

Pada gambar 11 menunjukkan sinyal *elektroensefalogram* (EEG) dari *channel* FP2 yang digambarkan terhadap waktu dalam satuan detik, dengan sumbu y merepresentasikan nilai amplitudo sinyal dalam satuan *mikrovolt* atau satuan terkait, dan sumbu x merepresentasikan waktu pengambilan data sepanjang 1000 detik. Grafik menampilkan variasi amplitudo yang berfluktuasi secara dinamis dengan rentang antara sekitar -20 hingga 25, menunjukkan adanya aktivitas otak yang berubah-ubah selama proses pencatatan. Tidak terdapat tren linier naik atau turun; sinyal bersifat osilatori dengan beberapa puncak amplitudo yang menonjol, khususnya di sekitar titik waktu 600 detik yang mungkin merefleksikan peningkatan aktivitas neuronal akibat stimulus atau artefak fisiologis.




Gambar 12. Filtering

Pada gambar 12 membandingkan efek filter *Notch* dan *Bandpass* pada sinyal EEG kanal FP2, masing-masing ditampilkan pada dua *plot* terpisah antara data mentah dan hasil pemrosesan sinyal. *Filter Notch* digunakan untuk menghilangkan frekuensi gangguan spesifik, biasanya *noise* listrik 50/60 Hz yang sering muncul pada data EEG di lingkungan klinis atau laboratorium. Pada *plot* kiri, sinyal *Raw* (biru) dibandingkan dengan sinyal setelah *Notch* (oranye). Sinyal hasil *filtering* tetap mempertahankan pola dasar sinyal tetapi amplitudonya tampak sedikit lebih "bersih", dengan fluktuasi kecil di sekitar baseline yang lebih stabil. Efek utama dari filter *Notch* adalah mengurangi komponen frekuensi tinggi yang merupakan artefak listrik tanpa mengubah karakter sinyal asli secara signifikan.

Filter Bandpass (BP7-13) digunakan untuk mengekstraksi rentang frekuensi tertentu, dalam hal ini 7–13 Hz yang umumnya mengacu pada pita gelombang alpha pada EEG. Pada *plot* kanan, sinyal mentah (*Raw*, biru) menunjukkan fluktuasi yang kompleks dengan artefak dan *noise*. Sinyal BP7-13 (oranye) tampak lebih halus dan hanya menyisakan aktivitas di rentang alpha, menghilangkan komponen lain di luar rentang ini sehingga sinyal hasil *bandpass* cenderung lebih bersih namun lebih datar.


Filter bandpass sangat penting untuk analisis karakteristik gelombang otak tertentu seperti *alpha*, *beta*, *theta*, dan *delta* yang masing-masing berasosiasi dengan aktivitas otak berbeda, misalnya relaksasi, fokus, dan tidur.



Gambar 13. Windowing


Pada gambar 13 menunjukkan perbandingan hasil pemrosesan *windowing* bertahap pada sinyal tersebut, yang digambarkan terhadap waktu dalam satuan detik. Terlihat bahwa kedua proses (*Step 1* dan *Step 2*) menghasilkan sinyal yang mengikuti pola sinyal asli, namun dengan *amplitudo* yang sedikit lebih

rendah dan kurva yang lebih mulus, mengindikasikan *attenuasi noise* dan penyaringan komponen tak diinginkan. Perbedaan antara *Step 1* dan *Step 2* umumnya menandakan bahwa *Step 2* merupakan pemurnian atau penyaringan lanjutan, seperti pengaplikasian *filter bandpass* setelah *notch*, atau sebaliknya, sehingga sinyal yang dihasilkan makin mendekati karakteristik ideal untuk analisis EEG lebih lanjut. Semakin bertambahnya proses *filtering*, sinyal semakin bersih namun juga dapat berisiko kehilangan komponen berharga jika filter terlalu ketat, sehingga diperlukan pemilihan parameter *filter* yang tepat dalam analisis data EEG.



Gambar 14 Standard Scaler

Pada gambar14 menampilkan perbandingan sinyal asli (*window*) dengan sinyal hasil transformasi *StandardScaler* dengan mengubah data agar memiliki rata-rata (*mean*) = 0 dan standar *deviasi* (σ) = 1. Akibatnya, skala amplitudo sinyal menjadi lebih kecil dibandingkan sinyal *window*. Pola gelombang tidak berubah (masih mengikuti bentuk asli), namun nilai amplitudonya lebih terkontrol. Hal ini dapat dilihat pada gambar, di mana amplitudo maksimum sinyal oranye berada di sekitar ± 1.5 , berbeda dengan sinyal biru yang bisa mencapai ± 2.5 . Proses *Standard Scaling* berhasil menormalkan sinyal sehingga memiliki skala yang seragam dengan *mean* = 0 dan standar *deviasi* = 1. Perbedaan mencolok terlihat pada *amplitudo* yang lebih kecil dan konsisten pada sinyal hasil *scaling*, tetapi pola gelombang masih identik dengan sinyal asli.



Gambar 15 Hasil *Principal component analysis*

Pada gambar 15 menampilkan perbandingan data EEG sebelum Data RAW dan sesudah *Principal Component Analysis* (PCA) data. *Plot 3d* menampilkan sinyal EEG dari berbagai kanal elektroda (Fp1, Fp2, F3, F4, C3, C4, P3, P4). Terlihat bahwa sebaran data masih cukup kompleks dan tumpang tindih, karena setiap kanal membawa informasi amplitudo dan waktu yang berbeda. Hal ini menunjukkan bahwa data mentah memiliki dimensi tinggi, sehingga sulit untuk dianalisis langsung atau divisualisasikan secara sederhana.


PCA (*Principal Component Analysis*) mereduksi dimensi data dari banyak kanal menjadi kombinasi linier yang disebut *principal components* (PCs). Pada grafik terlihat penyederhanaan data menjadi PC1 dan PC2, yang mewakili sebagian besar variasi dari data mentah. Sebaran titik lebih terkonsentrasi, pola distribusi lebih mudah dibedakan, dan kompleksitas berkurang. Warna gradasi mewakili nilai PC, memperlihatkan distribusi variasi utama dalam dataset.

Data mentah kompleks, banyak tumpang tindih, sulit dipisahkan antar pola sinyal. Data PCA lebih sederhana, pola distribusi terlihat lebih jelas, dan informasi utama tetap dipertahankan meskipun dimensi berkurang. Dengan PCA, redundansi antar kanal EEG berkurang, namun informasi dominan tetap ada sehingga data lebih efisien untuk proses selanjutnya (misalnya klasifikasi, *clustering*, atau deteksi pola gelombang otak).

Tabel 1. Hasil akurasi pengklasifikasian *Deep Evolving Denoising Autoencoder*

No	Responden	Akurasi (%)	Loss (%)	Waktu Training (Detik)
1	Responden A	94.35334	1.261261	4.413116
2	Responden B1	97.165486	0.566399	1.029345
3	Responden B2	95.169273	1.213443	2.004184
4	Responden C	97.316373	0.561104	1.700747
5	Responden F1	96.669016	0.560369	1.118349
Rata -Rata		96.1350964	0.8325152	2.0531482

Pada tabel 1 model *Deep Evolving Denoising Autoencoder* (DEV DAN) menghasilkan rata-rata akurasi klasifikasi adalah 96.13%, menunjukkan bahwa sistem mampu mengenali pola dengan tingkat keberhasilan yang sangat tinggi. Akurasi tertinggi dicapai pada responden B1 (97.16%) dan terendah pada responden A (94.35%). Rata-rata nilai *loss* adalah 0.83, dengan variasi antara 0.56 (paling rendah pada responden F1 dan B1) hingga 1.26 (paling tinggi pada responden A). Nilai *loss* yang rendah mengindikasikan bahwa model berhasil meminimalkan kesalahan prediksi. Hubungan terlihat jelas responden dengan akurasi tinggi cenderung memiliki *loss* lebih rendah. Perbedaan antar responden relatif kecil (sekitar 2–3%), yang menandakan bahwa sistem cukup konsisten terhadap variasi individu. Rata-rata waktu training adalah 2.05 detik. Responden dengan waktu *training* tercepat adalah F1 (1.18 detik), sedangkan yang paling lama adalah A (4.41 detik). Variasi waktu *training* dapat dipengaruhi oleh kompleksitas data dari masing-masing responden atau jumlah *epoch* yang dibutuhkan untuk mencapai konvergensi.




Gambar 16. Grafik Akurasi dan Loss

Pada gambar 16 Grafik akurasi (baris atas) untuk masing-masing responden menunjukkan fluktuasi nilai yang cukup tinggi sepanjang iterasi. Rata-rata akurasi tetap berada di rentang 50–100%, meskipun terdapat ketidakstabilan pada beberapa titik iterasi. Responden 2 dan 3 cenderung memiliki akurasi lebih stabil di kisaran tinggi dibandingkan responden lain. Responden 1 dan 5 menunjukkan variasi yang lebih besar, menandakan bahwa proses pelatihan pada data mereka lebih dinamis.

Grafik *loss* (baris bawah) menunjukkan tren naik-turun (*fluktuatif*), namun secara umum masih dalam batas normal untuk proses training dengan data bervariasi. *Loss* responden 2, 4, dan 5 tampak lebih stabil

pada nilai rendah, menandakan bahwa model lebih cepat menemukan pola pada data mereka. Sebaliknya, responden 1 dan 3 memiliki *loss* yang lebih sering melonjak, meskipun akhirnya tetap terkendali. Hal ini sesuai dengan tabel sebelumnya, di mana *loss* terendah diperoleh pada responden B1 dan F1, sejalan dengan akurasi yang relatif tinggi.



Gambar 17 Confusion matrix

Pada gambar 17 diprediksi sebagai f2 dan f3, menunjukkan ada kemiripan fitur di antara kelas ini. f4 salah ke f5, menandakan dua kelas ini memiliki karakteristik mirip dalam data. f2 relatif lebih bersih, dengan kesalahan sangat kecil berarti fitur kelas ini cukup unik. Distribusi data kelas f1 dan f4 memiliki jumlah data benar yang paling besar (>1000). Kelas f2 memiliki jumlah data lebih sedikit, sehingga lebih rawan *imbalance*. Secara keseluruhan distribusi data seimbang, karena tiap kelas memiliki prediksi benar yang cukup tinggi.

5. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi gerakan jari menggunakan sinyal EEG berbasis *Deep Evolving Denoising Autoencoder* (DEV DAN) yang memiliki kemampuan incremental learning dan adaptasi struktural. Pengolahan sinyal EEG melalui *filtering*, *windowing*, normalisasi dengan *Standard Scaler*, dan reduksi dimensi PCA berhasil meningkatkan kualitas data untuk klasifikasi. Model DEV DAN menunjukkan performa klasifikasi yang sangat tinggi dengan akurasi rata-rata 96,13% pada beberapa responden, serta *loss* yang rendah, mengindikasikan kemampuan model dalam mengenali pola sinyal EEG dengan sedikit kesalahan.

Analisis grafik akurasi dan *loss* selama proses pelatihan menunjukkan kestabilan performa model meskipun terdapat fluktuasi, dengan responden tertentu menunjukkan konsistensi yang lebih baik. Distribusi data antar kelas relatif seimbang dengan beberapa kelas yang memiliki fitur cukup unik sehingga memudahkan klasifikasi.

REFERENSI

- [1] Trisnawati, R. B. Anggraini, and R. Nurvinanda, "Faktor-Faktor Yang Berhubungan Dengan Terjadinya Ulkus Diabetikum Pada Penderita Diabetes Melitus," *Indones. J. Nurs. Heal. Sci.*, vol. 4, no. 2, pp. 85–94, 2023, [Online]. Available: <http://jurnal.globalhealthsciencegroup.com/index.php/IJNHS>
- [2] T. Das, L. Gohain, N. M. Kakoty, M. B. Malarvili, P. Widiyanti, and G. Kumar, "Hierarchical approach for fusion of electroencephalography and electromyography for predicting finger movements and kinematics using deep learning," *Neurocomputing*, vol. 527, pp. 184–195, 2023, doi: <https://doi.org/10.1016/j.neucom.2023.01.061>.
- [3] Laili Nur Azizah and I. N. Istiqomah, *Inovasi Aplikasi Si Rida Untuk Deteksi Risiko Kaki Diabetik*. Nuansa Fajar Cemerlang Grand Slipi Tower, Lantai 5 Unit F Jakarta Barat, 11480 Anggota IKAPI (624/DKI/2022), 2021.
- [4] W. W. Sakti, K. Anam, M. Pratama, S. Bukhori, F. S. Hanggara, and B. Liswanto, "Brain-Computer Interface based on Neural Network with Dynamically Evolved for Hand Movement Classification," in *2022 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE)*, 2022, pp. 72–75. doi: 10.1109/FORTEI-ICEE57243.2022.9972909.
- [5] M. Y. T. Sulistyono, D. Ernawati, K. Nathania, S. Dan, and R. S. Ramadani, "Pengolahan sinyal EEG sebagai indikator tindak lanjut pengambilan keputusan rehabilitasi medis pasien stroke," *Pros. Semin. Nas. Ilmu Tek. dan Apl. Ind.*, vol. 4, p. 124, 2021.

- [6] M. T. Sulistyono, "Pengambilan Data Pasien Stroke Menggunakan Sinyal EEG Sebagai Informasi Pengambilan Keputusan Melakukan Tindak Lanjut Rehabilitasi," *JOINS (Journal Inf. Syst.*, vol. 6, no. 1, pp. 83–93, 2021, doi: 10.33633/joins.v6i1.4474.
- [7] W. W. Sakti, K. Anam, S. B. Utomo, B. Marhaenanto, and S. Nahela, "Artificial Intelligence IoT based EEG Application using Deep Learning for Movement Classification," in *2021 8th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, IEEE, Oct. 2021, pp. 192–196. doi: 10.23919/EECSI53397.2021.9624269.
- [8] M. T. Sulistyono, "Penyaringan Noise Melalui Band Pass Filter Berbasis Sinyal Eeg Sebagai Langkah Awal Pengolahan Data Dalam Pengambilan Keputusan Reabilitasi Medis Pasien Stroke," *Pros. Sains Nas. dan Teknol.*, vol. 13, no. 1, pp. 179–184, 2023, doi: 10.36499/psnst.v13i1.9137.
- [9] Z. Khakim and S. Kusrohmaniah, "Dasar - Dasar Electroencephalography (EEG) bagi Riset Psikologi," *Bul. Psikol.*, vol. 29, no. 1, p. 92, 2021, doi: 10.22146/buletinpsikologi.52328.
- [10] A. S. Saragih, H. N. Basyiri, and M. Y. Raihan, "Analysis of motor imagery data from EEG device to move prosthetic hands by using deep learning classification," *AIP Conf. Proc.*, vol. 2537, no. 1, p. 50009, Aug. 2022, doi: 10.1063/5.0098178.
- [11] A. S. Saragih, A. Pamungkas, B. Y. Zain, W. Ahmed, and A. S. Saragih, "Electroencephalogram (EEG) signal classification using artificial neural network to control electric artificial hand movement," *IOP Conf. Ser. Mater. Sci. Eng.*, vol. 938, no. 1, 2020, doi: 10.1088/1757-899X/938/1/012005.
- [12] L. Ji, L. Yi, C. Huang, H. Li, W. Han, and N. Zhang, "Classification of hand movements from EEG using a FusionNet based LSTM network.," *J. Neural Eng.*, vol. 21, no. 6, Nov. 2024, doi: 10.1088/1741-2552/ad905d.
- [13] I. M. A. Agastya, R. Marco, and N. F. Puspitasari, "Implementasi Deep Learning untuk Klasifikasi Motor Imagery pada Sinyal EEG," *J. Inf. Technol. Comput. Sci.*, vol. 8, no. 2, pp. 91–100, 2024, doi: https://doi.org/10.31328/jointecs.v8i2.6413.
- [14] X. Ping and W. Huang, "Interactive EEG Emotion Recognition with Incremental Gaussian Processes.," *Int. J. Neural Syst.*, vol. 35, no. 9, p. 2550041, Sep. 2025, doi: 10.1142/S0129065725500418.
- [15] X. Song and S. C. Yoon, "Incremental versus non-incremental learning in adaptive common spatial patterns," *2015 IEEE Signal Process. Med. Biol. Symp. - Proc.*, no. 3, pp. 3–6, 2016, doi: 10.1109/SPMB.2015.7405468.
- [16] Y. Tachibana *et al.*, "A systematic review and meta-analysis of comprehensive interventions for pre-school children with autism spectrum disorder (ASD)," *PLoS One*, vol. 12, no. 12, pp. 1–28, 2017, doi: 10.1371/journal.pone.0186502.
- [17] X. Zhang, G. Xu, A. Ravi, W. Yan, and N. Jiang, "Fusing Frontal and Occipital EEG Features to Detect 'brain Switch' by Utilizing Convolutional Neural Network," *IEEE Access*, vol. 7, pp. 82817–82825, 2019, doi: 10.1109/ACCESS.2019.2924185.
- [18] D. Steyrl, G. Krausz, Y. Wang, L. Cao, and L. Fiedler, "Electroencephalogram (EEG) Signal Classification Using Artificial Neural Network to Control Electric Artificial Hand Movement Electroencephalogram (EEG) Signal Classification Using Artificial Neural Network to Control Electric Artificial Hand Movement," 2020, doi: 10.1088/1757-899X/938/1/012005.
- [19] D. P. Alisson Constantine, Victor Asanza, Alisson Constantin, Enrique Pel'aez, "System using a System using a System using a BCI System using a Selection for Hand Prosthesis," 2021, doi: 10.1016/j.ifacol.2021.10.283.
- [20] C. Piozin *et al.*, "Motion prediction for the sensorimotor control of hand prostheses with a brain-machine interface using EEG To cite this version : HAL Id : hal-03690432," 2022.
- [21] D. R. Cutipa-puma, C. G. Coaguila-quispe, and P. Raul, "HardwareX A low-cost robotic hand prosthesis with apparent haptic sense controlled by electroencephalographic signals," *HardwareX*, vol. 14, p. e00439, 2023, doi: 10.1016/j.ohx.2023.e00439.
- [22] M. Kaya, M. K. Binli, E. Ozbay, H. Yanar, and Y. Mishchenko, "Data descriptor: A large electroencephalographic motor imagery dataset for electroencephalographic brain computer interfaces," *Sci. Data*, vol. 5, no. October, pp. 1–16, 2018, doi: 10.1038/sdata.2018.211.
- [23] F. Y. Pamuji and V. P. Ramadhan, "Komparasi Algoritma Random Forest dan Decision Tree untuk Memprediksi Keberhasilan Immunotherapy," *J. Teknol. dan Manaj. Inform.*, vol. 7, no. 1, pp. 46–50, 2021, doi: 10.26905/jtmi.v7i1.5982.
- [24] A. M. Taqi, A. Awad, F. Al-Azzo, and M. Milanova, "The Impact of Multi-Optimizers and Data Augmentation on TensorFlow Convolutional Neural Network Performance," *Proc. - IEEE Ist Conf. Multimed. Inf. Process. Retrieval, MIPR 2018*, pp. 140–145, 2018, doi: 10.1109/MIPR.2018.00032.
- [25] S. Lasniari, J. Jasril, S. Sanjaya, F. Yanto, and M. Affandes, "Pengaruh Hyperparameter Convolutional Neural Network Arsitektur ResNet-50 Pada Klasifikasi Citra Daging Sapi dan Daging Babi," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 5, no. 3, pp. 474–481, 2022, doi: 10.32672/jnkti.v5i3.4424.