

# Identifikasi Emosi Melalui Sinyal Elektroensefalogram Menggunakan *Graph Convolutional Network*

VENA MEILINDA LIONITAMA, ESMERALDA CONTESSA DJAMAL, FATAN  
KASYIDI

Program Studi Informatika, Universitas Jenderal Achmad Yani  
Email: [esmeralda.contessa@lecture.unjani.ac.id](mailto:esmeralda.contessa@lecture.unjani.ac.id)

*Received 27 November 2023 | Revised 22 Januari 2024 | Accepted 15 Februari 2024*

## ABSTRAK

*Emosi merupakan bentuk respon manusia terhadap sesuatu. Pengenalan emosi menggunakan komputer dapat membantu para dokter untuk mengetahui emosi yang sedang dirasakan oleh seseorang berdasarkan aktivitas otak. Aktivitas otak dapat diketahui dengan cara merekam aktivitas sinyal Electroensefalogram (EEG). Sinyal EEG memiliki karakteristik yang berubah-ubah dan non stasioner sehingga membutuhkan metode yang dapat mengintegrasikan karakteristik temporal dan spasial. Pengenalan emosi menggunakan sinyal EEG berkaitan erat dengan pola konektivitas pada belahan otak manusia, karena setiap emosi akan memiliki pola konektivitas yang berbeda dalam belahan otak. Maka dari itu mempelajari pola konektivitas dalam belahan otak akan membantu dalam pengenalan emosi. Dan untuk menangani hal itu dibutuhkan metode deep learning yang dapat mengintegrasikan karakteristik temporal dan spasial dan dapat menerima masukan berupa pola konektivitas tersebut, metode yang dapat menanganinya yaitu, Graph Convolutional Network (GCN). Penelitian ini telah membuat sistem identifikasi emosi dengan tiga kelas menggunakan GCN dan menghasilkan akurasi data uji sebesar 35,52%.*

**Kata kunci:** Emosi; Deep Learning; Sinyal EEG; Spasial; Temporal; GCN

## ABSTRACT

*Emotion is a form of human response to something. Emotion recognition using computers can help doctors to see the emotions that are being felt by a person based on brain activity. Brain activity can be known by recording electroencephalogram (EEG) signal activity. EEG signals have changing and non-stationary characteristics, requiring a method to integrate temporal and spatial characteristics. Emotion recognition using EEG signals is closely related to connectivity patterns in the human brain hemispheres because each emotion will have different connectivity patterns in the brain hemispheres. Therefore, studying the connectivity patterns in the cerebral hemispheres will help in emotion recognition. Moreover, a deep learning method is needed to integrate temporal and spatial characteristics and receive input in the form of connectivity patterns, a method that can handle Graph Convolutional Network (GCN). This research has created an emotion identification system with three classes using GCN and produced an accuracy of 35.52% of testing data.*

**Keywords:** Emotion; Deep Learning; EEG Signal; Spatial; Temporal; GCN

## 1. PENDAHULUAN

Emosi menjadi hal yang menarik untuk diteliti karena, ia adalah bukti respon dari manusia terhadap sesuatu. Emosi dapat dikelompokkan menjadi emosi positif, netral, dan negatif. Emosi positif merupakan emosi yang menghadirkan rasa positif seperti bahagia, dan keyakinan. Emosi negatif adalah emosi yang dapat menghadirkan rasa yang tidak menyenangkan seperti takut, sedih, kecewa, gelisah, dan bersalah. Adapun yang mengelompokkan emosi berdasarkan dimensi valensi dan arousalnya. Emosi seseorang dapat ditebak dengan mudah oleh manusia tetapi bagi mesin, ini menjadi hal yang tidak mudah untuk dimengerti. Untuk membangkitkan emosi seseorang dapat melalui banyak cara, yaitu dengan mendengarkan musik (**Gonzalez & McMullen, 2020**), menonton *movie clips* (**Y. Li, dkk, 2021**), dan *video clips* (**Algarni, dkk, 2022**) (**J. Li, dkk, 2020**)

Salah satu cara untuk mengidentifikasi emosi adalah mengetahui aktivitas otak melalui sinyal Electroencephalogram (EEG). EEG telah banyak digunakan dalam penelitian dan ilmu medis. Dalam ilmu medis EEG dapat membantu dalam mendiagnosis epilepsi, gangguan tidur, bahkan dapat digunakan untuk menganalisis emosi. Sinyal EEG merupakan sinyal bioelektrik yang dihasilkan dari aktivitas otak manusia. Sinyal EEG memiliki amplitudo yang sangat rendah serta pola yang kompleks. Selain itu, sinyal EEG memiliki sifat non stationer serta mudah dipengaruhi oleh rangsangan dari luar yang dapat menambah kompleksitas dalam pemrosesan sinyal EEG. Informasi yang didapat dari sinyal EEG tergantung pada letak elektroda EEG di otak. Bahkan belahan otak kanan dan kiri pun akan menghasilkan informasi yang berbeda. Di dalam sinyal EEG terdapat fitur spasial dan temporal yang akan sangat dibutuhkan saat pemrosesan sinyal EEG. Spasial adalah sinyal antar kanal, dan temporal adalah waktu. Pada penelitian terdahulu menggunakan metode 3D CNN (**Kim, dkk, 2022**) dan adapula peneliti yang menggunakan algoritma deep forest (**Cheng, dkk, 2021**) untuk mengekstraksi fitur spatiotemporal, dimana fitur spasial dan temporal akan langsung diekstraksi dengan metode yang sama. Kelemahan dari ekstraksi fitur spatiotemporal adalah fitur spasial dan temporal tidak diekstraksi secara efisien. Untuk mengatasi masalah tersebut digunakanlah metode paralel, dimana fitur spasial dan temporal akan diekstraksi menggunakan dua deep learning yang berbeda. Adapun peneliti yang menggunakan paralel hybrid 2D CNN untuk ekstraksi fitur spasial dan *Recurrent Neural Network* (RNN) untuk ekstraksi fitur temporal (**Putri, dkk, 2022**)(**Liang, dkk, 2021**). Kemudian peneliti selanjutnya menggunakan metode paralel 3D CNN untuk ekstraksi fitur spasial dan transformer untuk ekstraksi fitur temporal (**Sun, dkk, 2022**). Adapula peneliti yang menggunakan Multidimensional Graph Convolutional Network (MD-GCN) dengan hasil akurasi 92,15% untuk dataset SEED dan 90,19% untuk dataset SEED-IV. Pada penelitian disebutkan bahwa matriks ketetangaan didapatkan dari hasil korelasi matriks spasial dan matriks komunikasi. Matriks komunikasi menggunakan 9 pasang elektroda yang didapat dari penelitian sebelumnya yaitu (FP1, FP2), (AF3, AF4), (F5, F6), (FC5, FC6), (C5, C6), (CP5, CP6), (P5, P6), (PO5, PO6), dan (O1, O2) (**Du, dkk, 2022**). Penelitian (**Gao, dkk, 2022**) mengungkapkan bahwa matriks ketetangaan yang didapat dari penelitian sebelumnya dianggap lemah oleh karena itu untuk menyempurnakannya matriks ketetangaan dibuat dari hasil self-learning. Penelitian tersebut menggunakan DEAP dan SEED dataset. Adapula peneliti menggunakan *Dynamic Graph Convolutional Neural Network* (DGCNN) dimana model yang dibangun dapat mempelajari fitur-fitur diskriminatif untuk meningkatkan kemampuan pengenalan emosi, tetapi penelitian tersebut mengabaikan bahwa belahan otak manusia akan menghasilkan emosi yang berbeda (**Song, dkk, 2020**).

Sinyal EEG memiliki terlalu banyak noise sehingga untuk menggunakannya dibutuhkan sebuah proses filtrasi. Proses filtrasi merupakan proses untuk mendapatkan rentang gelombang yang akan ditinjau. Wavelet merupakan sebuah metode untuk memfilter frekuensi dan metode

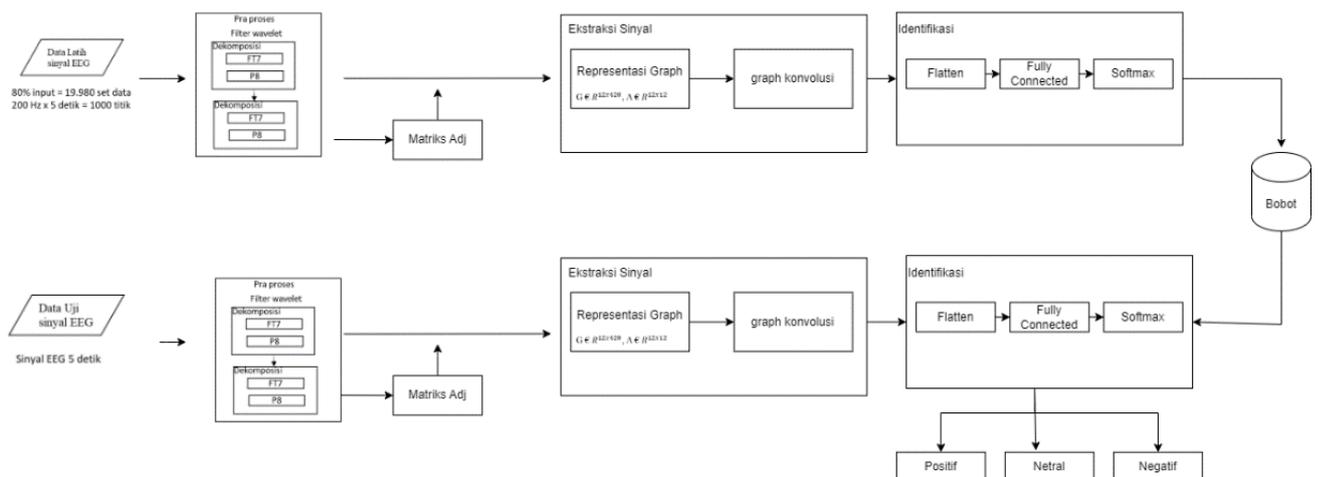
untuk menghilangkan noise sehingga sinyal tidak terganggu oleh hal lainnya. Penelitian sebelumnya menggunakan filter wavelet untuk mendapatkan rentang frekuensi 4-45 Hz (**Haqqe, dkk, 2021**).

Untuk mengidentifikasi emosi tidak hanya melalui sinyal EEG tetapi melalui video ekspresi wajah, seperti yang dilakukan oleh peneliti terdahulu dengan menggabungkan sinyal EEG dan video ekspresi wajah dengan menggunakan metode Library Support Vector Machine (LIBSVM), penelitian tersebut menghasilkan akurasi 85,71% (**Zhang, 2020**). Penelitian ini membuat sistem yang dapat mengidentifikasi emosi melalui sinyal EEG menggunakan GCN hasil dari penelitian ini diklasifikasikan ke dalam 3 kelas yaitu, "positif, netral, dan negatif". Kompleksitas pemrosesan sinyal EEG memberikan tantangan tersendiri untuk identifikasi. Meskipun penelitian terdahulu sudah banyak, namun perlu mencoba kemungkinan kombinasi metode lain untuk mencoba.

## 2. METODE PENELITIAN

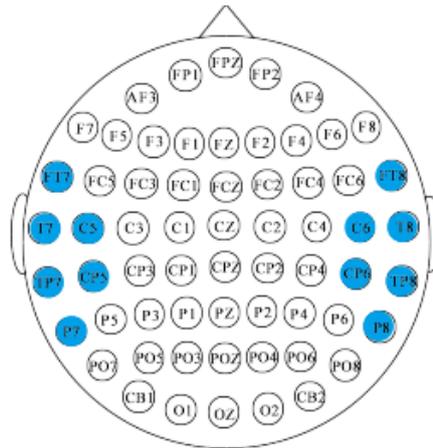
### 2.1. Arsitektur Sistem

Arsitektur Sistem Identifikasi Emosi Sinyal EEG dengan menggunakan metode GCN ditunjukkan pada Gambar 1.



**Gambar 1. Sistem Identifikasi Emosi**

Dari Gambar 1 dapat dilihat bahwa tahap pertama yaitu perolehan data. Data yang akan digunakan pada penelitian ini didapat dari public dataset yaitu SJTU Emotion EEG Dataset (SEED). Dimana data diperoleh dari hasil perekaman 15 siswa (7 pria dan 8 wanita) dengan penglihatan dan pendengaran yang normal. Perekaman menggunakan ESI Neurascan EEG device dengan frekuensi sampling 200 Hz. Perekaman pun menggunakan stimulus 15 cuplikan film China dengan durasi 4 menit dalam 5 sesi. Penelitian sebelumnya menggunakan 12 kanal dari 62 kanal yang terdiri dari FT7, FT8, T7, T8, C5, C6, TP7, TP8, CP5, CP6, P7, P8 (**Haqqe, dkk, 2021**). Peletakan kanal yang digunakan ditunjukkan pada Gambar 2. Data tersebut kemudian dibagi menjadi set data latih dan set data uji.



**Gambar 2. Peletakan Kanal**

Tahap kedua yaitu pra proses. Pra-proses dilakukan untuk mendapatkan informasi yang akan digunakan saat proses identifikasi. Pra-proses dalam penelitian ini terdiri dari segmentasi dan filterisasi wavelet. Data sinyal EEG memiliki durasi sepanjang 185 detik. Setiap sinyal disegmentasi setiap 5 detik. Sehingga set data berjumlah 15 subjek x 3 sesi x 15 percobaan x 37 segmentasi atau berjumlah 24.975 set data. Dari 24.975 set data akan dibagi 80% atau 19.980 set data untuk data latih dan 20% atau 4.995 set data set data uji. Sementara itu, untuk titik pada kanal berjumlah 200 Hz x 5 detik atau sebanyak 1000 titik. Pada tahap selanjutnya sinyal akan di filter menggunakan wavelet dengan rentang frekuensi 4-45 Hz.

Tahap ketiga yaitu sistem identifikasi sinyal EEG. Pada tahap identifikasi sinyal terdiri dari dua bagian yaitu, ekstraksi fitur dan identifikasi. Sinyal yang telah melalui pra proses diidentifikasi menggunakan GCN dan akan menghasilkan 3 kelas emosi yaitu, negatif, netral, dan positif.

## 2.2. Perolehan Data

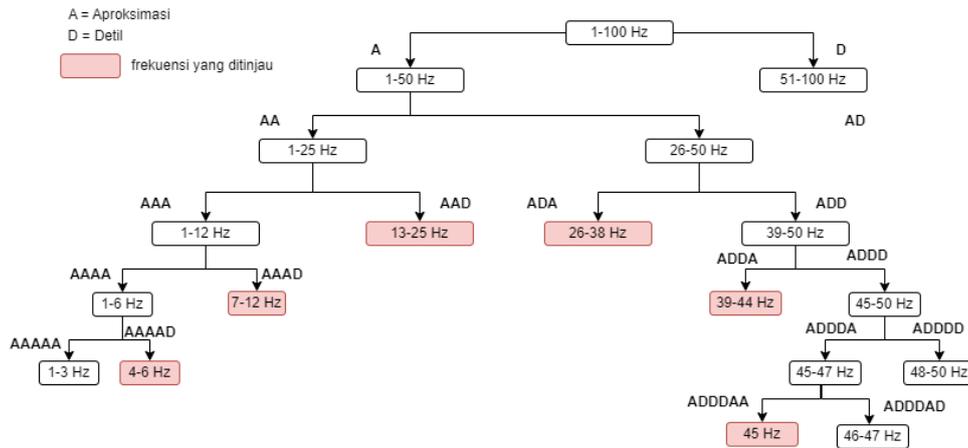
Data yang digunakan merupakan data public yaitu SJTU Emotion EEG Dataset (SEED). Data diperoleh dari hasil perekaman 15 siswa (7 pria dan 8 wanita) dengan penglihatan dan pendengaran yang normal. Perekaman menggunakan ESI Neuroscan EEG device dengan frekuensi sampling 1000 Hz yang dikurangi menjadi 200 Hz. Perekaman menggunakan stimulus 15 cuplikan film China dengan durasi 4 menit dalam 5 sesi (**Zheng & Lu, 2015**). Data yang diperoleh di segmentasi setiap 5 detik sehingga didapatkan 200 Hz x 5 detik = 1000 titik data pada setiap segmen, dengan total 15 subjek x 3 sesi x 15 perulangan x 37 segmentasi = 24.975 set data. Data sinyal EEG tersebut merupakan file bertipe \*.csv. Dari jumlah set data akan dibagi menjadi data latih dan data uji, dimana 80% atau 19.980 set data untuk data latih dan 20% atau 4.995 set data untuk data uji.

## 2.3. Filter Wavelet

Ekstraksi Wavelet digunakan untuk mendapatkan komponen frekuensi dalam rentang gelombang yang akan ditinjau. Dalam frekuensi 1-200 Hz memungkinkan informasi sinyal berada di 1-200/2 Hz atau sering disebut dengan frekuensi Nyquist. Filter Wavelet digunakan untuk mendapatkan rentang frekuensi yang diinginkan yaitu 4-45 Hz menggunakan dekomposisi seperti Gambar 3. Pada penelitian ini menggunakan Wavelet Daubechies4. Fungsi Wavelet dasar dapat dinyatakan menggunakan Persamaan (1).

$$\psi_{\sigma,\tau}(n) = \frac{1}{\sqrt{|\sigma|}} \psi\left(\frac{n-\tau}{\sigma}\right) \quad (1)$$

# Identifikasi Emosi Melalui Sinyal EEG Menggunakan Graph Convolutional Network



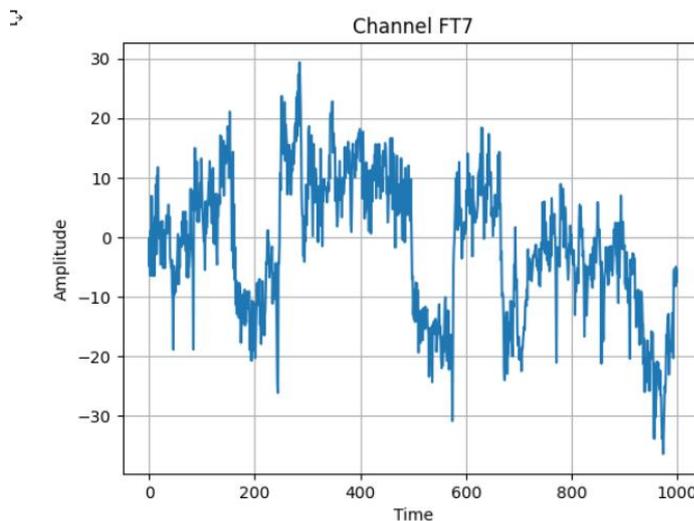
**Gambar 3. Ekstraksi Wavelet**

Filter wavelet terdiri dari 2 proses utama, yaitu dekomposisi dan rekontruksi. Dekomposisi adalah proses ekstraksi sinyal ke dalam frekuensi tertentu, sedangkan rekontruksi adalah proses penggabungan kembali sinyal ke bentuk semula. Dekomposisi menghasilkan aproksimasi dan detil. Aproksimasi adalah hasil proses konvolusi sinyal asli terhadap low-pass filter, dan detil adalah hasil proses konvolusi sinyal asli terhadap high-pass filter. Untuk memperoleh aproksimasi dijelaskan pada Persamaan (2) dan untuk detil pada Persamaan (3).

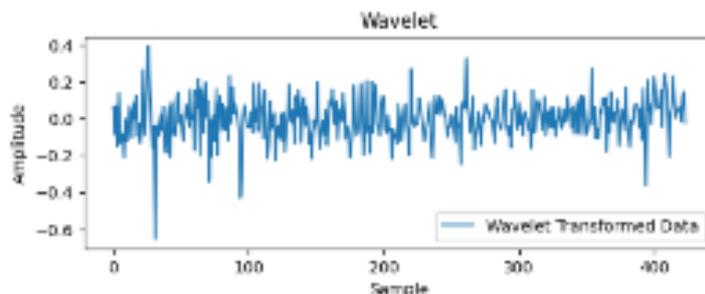
$$y_{low}(i) = \sum_n x(n).g(2i - n) \tag{2}$$

$$y_{high}(i) = \sum_n x(n).h(i - n) \tag{3}$$

Dimana  $g(2i - n)$  merupakan koefisien *low-pass filter*, dan  $h(i - n)$  merupakan koefisien *high-pass filter*. Selanjutnya Gambar 4 dan Gambar 5 akan menunjukkan perbedaan sinyal sebelum dan sesudah filterisasi menggunakan Wavelet.



**Gambar 4. Sinyal Asli EEG**



**Gambar 5. Sinyal hasil Wavelet**

#### **2.4. Graph Convolutional Network**

GCN merupakan inovasi dari CNN. GCN menerima masukan berupa data dan matriks adjacency, matriks adjacency merupakan matriks yang merepresentasikan konektivitas antar node, node disini merupakan fitur dari setiap kanal. GCN memiliki arsitektur seperti CNN yaitu, lapisan konvolusi, pooling, dan lapisan identifikasi.

Di dalam *graph*, sinyal EEG di representasikan sebagai  $G = \{V, E, A\}$ . Dimana  $V$  merupakan representasi dari kanal,  $E$  merupakan hubungan antar kanal, dan  $A$  merupakan matriks adjacency. Setelah ditentukan graph, maka selanjutnya adalah membangun matriks Laplacian menggunakan Persamaan (4).

$$L = D - A \quad (4)$$

Dimana  $D$  merupakan matriks Degree. Selanjutnya matriks Laplacian yang sebelumnya dibentuk akan diubah menjadi diagonal menggunakan Persamaan (5).

$$L = U \Lambda U^T \quad (5)$$

Dimana  $U$  merupakan orthogonal dari  $L$ , dan  $\Lambda$  merupakan eigenvalues dari  $L$ . Jika sudah maka selanjutnya adalah proses konvolusi.

Lapisan konvolusi merupakan lapisan yang mengubah data dengan operasi perkalian matriks atau dot product antara data masukan dengan matriks adjacency. Operasi konvolusi menggunakan Persamaan (6).

$$c * x = g(L)x \quad (6)$$

Dimana  $c$  merupakan kernel, dan  $x$  merupakan graph data.

### **3. HASIL DAN PEMBAHASAN**

Penelitian ini melakukan filter sinyal EEG menggunakan Wavelet pada rentang frekuensi 4-45 Hz. Kemudian dari 24.975 set data dibagi menjadi 80% atau 19.980 set data yang digunakan untuk pelatihan, sedangkan 20% atau 4.995 set data digunakan untuk pengujian. Dengan jumlah kanal yang digunakan adalah 12 kanal yang digunakan meliputi FT7, FT8, T7, T8, C5, C6, TP7, TP8, CP5, CP6, P7, dan P8. Wavelet mengurangi sinyal dari 12.000 menjadi 5.088 titik data untuk setiap saluran. Hasil dari filter Wavelet digunakan sebagai input dalam identifikasi sinyal EEG yang digunakan dalam metode GCN menjadi tiga kelas, yaitu: Positif, Netral, dan Negatif

### 3.1 Teknik Koreksi Bobot

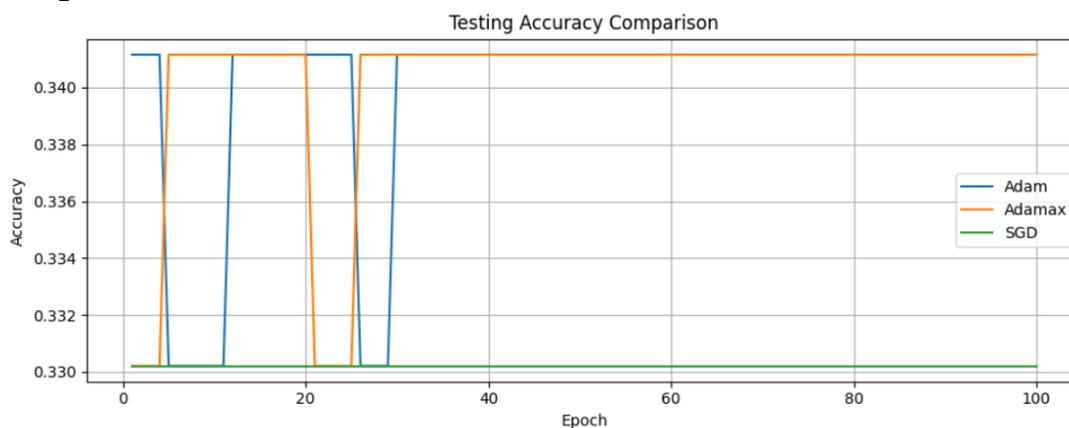
Ekspirimen ini membandingkan empat jenis teknik pengoptimalan. Ini menggunakan *Stochastic Gradient Descent* (SGD), *Adaptive Moment* (Adam), dan *Adaptive Moment with Maximum* (AdaMax) untuk meninjau koreksi bobot kinerja parameter yang diperbarui dalam metode yang diusulkan dengan hasil yang ditunjukkan pada Tabel 1.

**Tabel 1. Perbandingan Teknik Koreksi Bobot**

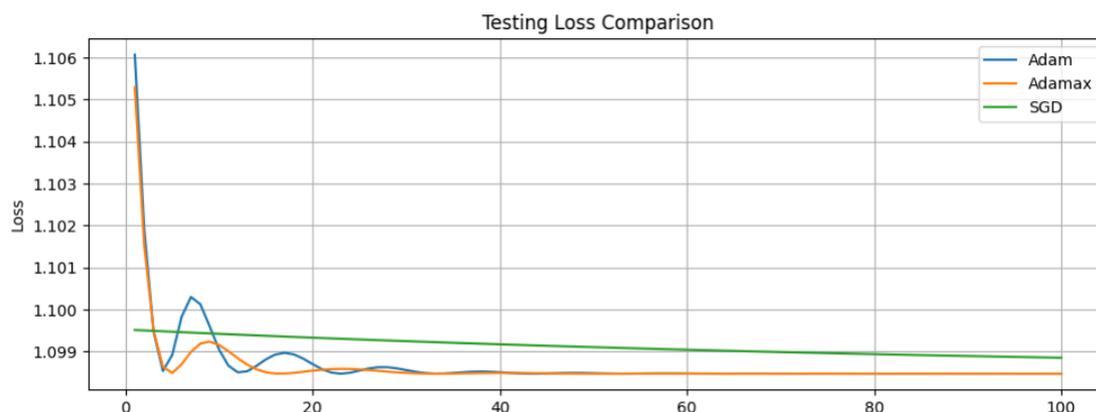
Teknik Pengoptimalan	Akurasi (%)	Loss	Waktu (menit)
SGD	33.02	1.09	0.55
Adam	34.12	1.09	0.66
AdaMax	34.12	1.09	0.46

Dari Tabel 1 dapat dilihat bahwa akurasi menggunakan SGD lebih rendah dibandingkan dengan Adam dan AdaMax. Untuk Adam dan AdaMax hasil akurasi sama tetapi dilihat dari waktunya AdaMax membutuhkan waktu learning lebih cepat dibandingkan dengan Adam.

Pada Gambar 6 akurasi menggunakan AdaMax hanya mengalami satu kali penurunan setelah itu kembali stabil. Dan untuk perbandingan loss dapat dilihat pada Gambar 7, Adam dan AdaMax menurun secara perlahan, tetapi model optimasi AdaMax lebih cepat konvergen dibandingkan SGD dan Adam.



**Gambar 6. Perbandingan Akurasi SGD, Adam, AdaMax**



**Gambar 7. Perbandingan Loss SGD, Adam, AdaMax**

**3.2 Perbandingan Dengan Metode Sebelumnya Menggunakan Dataset yang Sama**  
 Beberapa penelitian sebelumnya menggunakan dataset SEED dengan metode yang berbeda untuk mengidentifikasi emosi, seperti pada Tabel 2.

**Tabel 2. Perbandingan dengan Penelitian Sebelumnya**

Metode	Akurasi
MDGCN (Du et al., 2022)	92,15
EEG-GCN (Gao et al., 2022)	85,65
GCN (metode yang diajukan)	34,12

Seperti yang dilihat pada Tabel 2, Peneliti terdahulu yang menggunakan metode MDGCN menghasilkan akurasi lebih tinggi karena menggunakan matriks adjacency 9 pasang kanal sesuai dengan penelitian sebelumnya. Untuk peneliti terdahulu yang menggunakan EEG-GCN, matriks adjacency terbentuk dari keterhubungan antar kanal yang ditinjau. Walaupun akurasi yang rendah, namun GCN memberikan kelebihan dalam kecepatan kesetabilan, seperti pada Gambar 7.

#### 4. KESIMPULAN

Penelitian ini menggunakan metode GCN untuk identifikasi emosi melalui sinyal EEG. GCN dapat mempelajari pola konektivitas otak sesuai dengan emosi yang dirasa. Oleh karena itu, GCN digunakan untuk identifikasi emosi dengan akurasi 35,52%. Pada penelitian ini digunakan metode ekstraksi kanal yaitu Wavelet inilah yang menjadi kebaruan dari penelitian sebelumnya. Wavelet digunakan untuk mendapatkan rentang frekuensi yang diinginkan yaitu 4-45 Hz. Metode koreksi bobot yang digunakan dalam penelitian ini adalah AdaMax. Pada dasarnya Adam dan AdaMax hampir sama, hanya saja AdaMax lebih cepat konvergen dibandingkan Adam.

## DAFTAR RUJUKAN

- Algarni, M., Saeed, F., Al-Hadhrami, T., Ghabban, F., & Al-Sarem, M. (2022). Deep Learning-Based Approach for Emotion Recognition Using Electroencephalography (EEG) Signals Using Bi-Directional Long Short-Term Memory (Bi-LSTM). *Sensors*, 22(8). <https://doi.org/10.3390/s22082976>
- Cheng, J., Chen, M., Li, C., Liu, Y., Song, R., Liu, A., & Chen, X. (2021). Emotion Recognition from Multi-Channel EEG via Deep Forest. *IEEE Journal of Biomedical and Health Informatics*, 25(2), 453–464. <https://doi.org/10.1109/JBHI.2020.2995767>
- Du, G., Su, J., Zhang, L., Su, K., Wang, X., Teng, S., & Liu, P. X. (2022). A Multi-Dimensional Graph Convolution Network for EEG Emotion Recognition. *IEEE Transactions on Instrumentation and Measurement*, 71. <https://doi.org/10.1109/TIM.2022.3204314>
- Gao, Y., Fu, X., Ouyang, T., & Wang, Y. (2022). EEG-GCN: Spatio-Temporal and Self-Adaptive Graph Convolutional Networks for Single and Multi-View EEG-Based Emotion Recognition. *IEEE Signal Processing Letters*, 29, 1574–1578. <https://doi.org/10.1109/LSP.2022.3179946>
- Gonzalez, E. J. S., & McMullen, K. (2020). The Design of an Algorithmic Modal Music Platform for Eliciting and Detecting Emotion. *8th International Winter Conference on Brain-Computer Interface, BCI 2020*, 58–60. <https://doi.org/10.1109/BCI48061.2020.9061664>
- Haqqe, R. H. D., Djamal, E. C., & Wulandari, A. (2021). Emotion Recognition of EEG Signals Using Wavelet Filter and Convolutional Neural Networks. *Proceedings - 2021 8th International Conference on Advanced Informatics: Concepts, Theory, and Application, ICAICTA 2021*. <https://doi.org/10.1109/ICAICTA53211.2021.9640279>
- Kim, S., Kim, T. S., & Lee, W. H. (2022). Accelerating 3D Convolutional Neural Network with Channel Bottleneck Module for EEG-Based Emotion Recognition. *Sensors*, 22(18), 1–16. <https://doi.org/10.3390/s22186813>
- Li, J., Qiu, S., Du, C., Wang, Y., & He, H. (2020). Domain adaptation for eeg emotion recognition based on latent representation similarity. *IEEE Transactions on Cognitive and Developmental Systems*, 12(2), 344–353. <https://doi.org/10.1109/TCDS.2019.2949306>
- Li, Y., Zheng, W., Zong, Y., Cui, Z., Zhang, T., & Zhou, X. (2021). A Bi-Hemisphere Domain Adversarial Neural Network Model for EEG Emotion Recognition. *IEEE Transactions on Affective Computing*, 12(2), 494–504. <https://doi.org/10.1109/TAFFC.2018.2885474>
- Liang, Z., Zhou, R., Zhang, L., Li, L., Huang, G., Zhang, Z., & Ishii, S. (2021). EEGFuseNet: Hybrid Unsupervised Deep Feature Characterization and Fusion for High-Dimensional EEG with an Application to Emotion Recognition. *IEEE Transactions on Neural Systems and*

- Rehabilitation Engineering*, 29(1), 1913–1925.  
<https://doi.org/10.1109/TNSRE.2021.3111689>
- Putri, N. A., Contessa Djamal, E., Nugraha, F., & Kasyidi, F. (2022). EEG Emotion Recognition using Parallel Hybrid Convolutional-Recurrent Neural Networks. *2022 International Conference on Data Science and Its Applications, ICoDSA 2022*, 24–29.  
<https://doi.org/10.1109/ICoDSA55874.2022.9862853>
- Song, T., Zheng, W., Song, P., & Cui, Z. (2020). EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks. *IEEE Transactions on Affective Computing*, 11(3), 532–541. <https://doi.org/10.1109/TAFFC.2018.2817622>
- Sun, J., Wang, X., Zhao, K., Hao, S., & Wang, T. (2022). Multi-Channel EEG Emotion Recognition Based on Parallel Transformer and 3D-Convolutional Neural Network. *Mathematics*, 10(17). <https://doi.org/10.3390/math10173131>
- Zhang, H. (2020). Expression-eeG based collaborative multimodal emotion recognition using deep autoencoder. *IEEE Access*, 8, 164130–164143.  
<https://doi.org/10.1109/ACCESS.2020.3021994>
- Zheng, W. L., & Lu, B. L. (2015). Investigating Critical Frequency Bands and Channels for EEG-Based Emotion Recognition with Deep Neural Networks. *IEEE Transactions on Autonomous Mental Development*, 7(3), 162–175.  
<https://doi.org/10.1109/TAMD.2015.2431497>