

TUGAS AKHIR - EC234801

**KLASIFIKASI DEPRESI MENGGUNAKAN CNN BERBASIS
POWER SPECTRAL DENSITY PADA SINYAL EEG
RESTING STATE**

Mida Hasian

NRP 5024 21 1021

Dosen Pembimbing

Dr. Diah Puspito Wulandari, S.T., M.Sc.

NIP 19740907 200212 1 001

Dr. Eko Mulyanto Yuniarno, S.T., M.T.

NIP 19680601 199512 1 009

Program Studi Strata 1 (S1) Teknik Komputer

Departemen Teknik Komputer

Fakultas Teknologi Elektro dan Informatika Cerdas

Institut Teknologi Sepuluh Nopember

Surabaya

2025

[Halaman ini sengaja dikosongkan]



TUGAS AKHIR - EC234801

**KLASIFIKASI DEPRESI MENGGUNAKAN CNN
BERBASIS POWER SPECTRAL DENSITY PADA
SINYAL EEG RESTING STATE**

Mida Hasian

NRP 5024 21 1021

Dosen Pembimbing

Dr. Diah Puspito Wulandari, S.T., M.Sc.

NIP 19740907 200212 1 001

Dr. Eko Mulyanto Yuniarno, S.T., M.T.

NIP 19680601 199512 1 009

Program Studi Strata 1 (S1) Teknik Komputer

Departemen Teknik Komputer

Fakultas Teknologi Elektro dan Informatika Cerdas

Institut Teknologi Sepuluh Nopember

Surabaya

2025

[Halaman ini sengaja dikosongkan]



FINAL PROJECT - EC234801

**DEPRESSION CLASSIFICATION USING CNN BASED
ON POWER SPECTRAL DENSITY OF RESTING-STATE
EEG SIGNALS**

Mida Hasian

NRP 5024 21 1021

Advisor

Dr. Diah Puspito Wulandari, S.T., M.Sc.

NIP 19740907 200212 1 001

Dr. Eko Mulyanto Yuniarno, S.T., M.T.

NIP 19680601 199512 1 009

Undergraduate Study Program of Computer Engineering

Department of Computer Engineering

Faculty of Intelligent Electrical And Informatics Technology

Sepuluh Nopember Institute of Technology

Surabaya

2025

[Halaman ini sengaja dikosongkan]

LEMBAR PENGESAHAN

KLASIFIKASI DEPRESI MENGGUNAKAN CNN BERBASIS POWER SPECTRAL DENSITY PADA SINYAL EEG RESTING STATE

TUGAS AKHIR

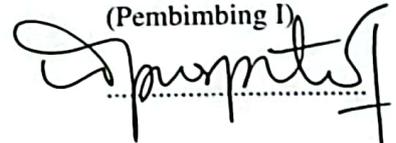
Diajukan untuk memenuhi salah satu syarat memperoleh gelar Sarjana Teknik pada Program Studi S-1 Teknik Komputer Departemen Teknik Komputer Fakultas Teknologi Elektro dan Informatika Cerdas Institut Teknologi Sepuluh Nopember

Oleh: **Mida Hasian**
NRP. 5024 21 1021

Disetujui oleh Tim Penguji Tugas Akhir:

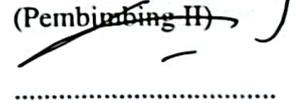
Dr. Diah Puspito Wulandari, S.T., M.Sc.
NIP: 19740907 200212 1 001

(Pembimbing I)



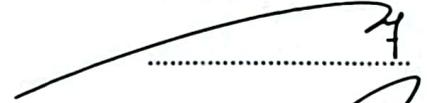
Dr. Eko Mulyanto Yuniarno, S.T., M.T.
NIP: 19680601 199512 1 009

(Pembimbing II)



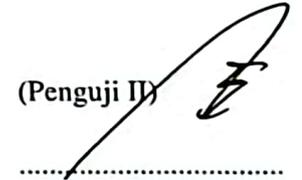
Dr. Arief Kurniawan, S.T., M.T.
NIP: 19740907200212 1 001

(Penguji I)



Arta Kusuma Hernanda, S.T., M.T.
NIP: 1996202311024

(Penguji II)



Yusril Izza, S.T., M.Comp.
NIP: 1992202511059

(Penguji II)



Mengetahui,
Kepala Departemen Teknik Komputer FTEIC - ITS


Dr. Arief Kurniawan, S.T., M.T.
NIP. 19740907200212 1 001

SURABAYA
Juli, 2025

[Halaman ini sengaja dikosongkan]

APPROVAL SHEET

DEPRESSION CLASSIFICATION USING CNN BASED ON POWER SPECTRAL DENSITY OF RESTING-STATE EEG SIGNALS

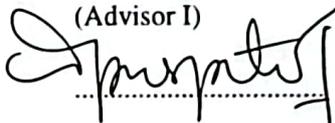
FINAL PROJECT

Submitted to fulfill one of the requirements
for obtaining a degree Bachelor of Engineering at
Undergraduate Study Program of Computer Engineering
Department of Computer Engineering
Faculty of Intelligent Electrical And Informatics Technology
Sepuluh Nopember Institute of Technology

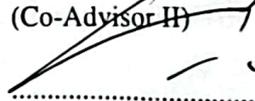
By: **Mida Hasian**
NRP. 5024 21 1021

Approved by Final Project Examiner Team:

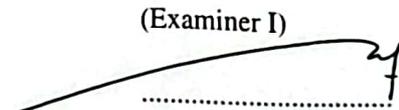
Dr. Diah Puspito Wulandari, S.T., M.Sc.
NIP: 19740907 200212 1 001

(Advisor I)


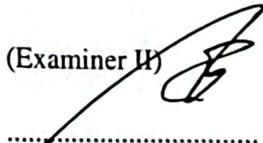
Dr. Eko Mulyanto Yuniarno, S.T., M.T.
NIP: 19680601 199512 1 009

(Co-Advisor II)


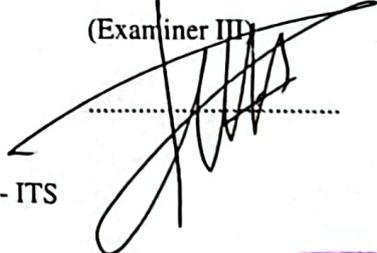
Dr. Arief Kurniawan, S.T., M.T.
NIP: 19740907200212 1 001

(Examiner I)


Arta Kusuma Hernanda, S.T., M.T..
NIP: 1996202311024

(Examiner II)


Yusril Izza, S.T., M.Comp.
NIP: 1992202511059

(Examiner III)


Acknowledged,
Head of Computer Engineering Department FIEI - ITS


Dr. Arief Kurniawan, S.T., M.T.
NIP. 19740907200212 1 001

SURABAYA
July, 2025

[Halaman ini sengaja dikosongkan]

PERNYATAAN ORISINALITAS

Yang bertanda tangan dibawah ini:

Nama Mahasiswa / NRP : Mida Hasian / 5024 21 1021
Departemen : Teknik Komputer
Dosen Pembimbing / NIP : Dr. Diah Puspito Wulandari, S.T., M.Sc. / 19740907 200212
1 001

Dengan ini menyatakan bahwa Tugas Akhir dengan judul "KLASIFIKASI DEPRESI MENGGUNAKAN CNN BERBASIS POWER SPECTRAL DENSITY PADA SINYAL EEG RESTING STATE" adalah hasil karya sendiri, bersifat orisinal, dan ditulis dengan mengikuti kaidah penulisan ilmiah.

Bilamana di kemudian hari ditemukan ketidaksesuaian dengan pernyataan ini, maka saya bersedia menerima sanksi sesuai dengan ketentuan yang berlaku di Institut Teknologi Sepuluh Nopember.

Surabaya, Juli 2025

Mengetahui
Dosen Pembimbing

Mahasiswa



Dr. Diah Puspito Wulandari, S.T., M.Sc.
NIP. 19740907 200212 1 001



Mida Hasian
NRP. 5024 21 1021

[Halaman ini sengaja dikosongkan]

STATEMENT OF ORIGINALITY

The undersigned below:

Name of student / NRP : Mida Hasian / 5024 21 1021
Department : Computer Engineering
Advisor / NIP : Dr. Diah Puspito Wulandari, S.T., M.Sc. / 19740907 200212 1
001

Hereby declared that the Final Project with the title of "DEPRESSION CLASSIFICATION USING CNN BASED ON POWER SPECTRAL DENSITY OF RESTING-STATE EEG SIGNALS" is the result of my own work, is original, and is written by following the rules of scientific writing.

If in future there is a discrepancy with this statement, then I am willing to accept sanctions in accordance with provisions that apply at Sepuluh Nopember Institute of Technology.

Surabaya, July 2025

Acknowledged
Advisor



Dr. Diah Puspito Wulandari, S.T., M.Sc.
NIP. 19740907 200212 1 001

Student



Mida Hasian
NRP. 5024 21 1021

[Halaman ini sengaja dikosongkan]

ABSTRAK

Nama Mahasiswa : Mida Hasian
Judul Tugas Akhir : KLASIFIKASI DEPRESI MENGGUNAKAN CNN BERBASIS POWER SPECTRAL DENSITY PADA SINYAL EEG RESTING STATE
Pembimbing : 1. Dr. Diah Puspito Wulandari, S.T., M.Sc.
2. Dr. Eko Mulyanto Yuniarno, S.T., M.T.

Depresi merupakan gangguan mental yang dapat berdampak signifikan terhadap kualitas hidup individu, sehingga diagnosis dini menjadi krusial untuk penanganan yang efektif. Salah satu metode non-invasif yang dapat digunakan untuk menganalisis aktivitas otak adalah *electroencephalography* (EEG), khususnya pada kondisi *resting state*. Penelitian ini bertujuan untuk mengklasifikasikan kondisi depresi pada individu dengan memanfaatkan fitur *Power Spectral Density* (PSD) dari sinyal EEG yang diproses menggunakan *Convolutional Neural Network* (CNN). Data EEG diambil dari dataset MODMA, dengan rekaman dari delapan kanal EEG terpilih, yang melalui tahapan pra-pemrosesan seperti filterisasi, segmentasi waktu, dan ekstraksi fitur PSD. Dua arsitektur CNN diusulkan, dengan Model 2 menunjukkan kinerja lebih baik, mencapai akurasi 99%, *precision* 1.00 pada kelas depresi, dan *recall* 0.98, dibandingkan Model 1 dengan akurasi 98%. Hasil penelitian menunjukkan bahwa kombinasi PSD dan CNN mampu mengklasifikasikan kondisi depresi dengan akurasi tinggi pada dataset *resting state*. Namun, performa model menurun pada dataset dengan kondisi *activate state*, sehingga penelitian lanjutan disarankan untuk mengeksplorasi strategi peningkatan generalisasi model terhadap variasi data yang lebih kompleks.

Kata Kunci: Depresi, EEG, Power Spectral Density, Convolutional Neural Network, Klasifikasi

[Halaman ini sengaja dikosongkan]

ABSTRACT

Name : Mida Hasian
Title : DEPRESSION CLASSIFICATION USING CNN BASED ON POWER SPECTRAL DENSITY OF RESTING-STATE EEG SIGNALS
Advisors : 1. Dr. Diah Puspito Wulandari, S.T., M.Sc.
2. Dr. Eko Mulyanto Yuniarno, S.T., M.T.

Depression is a mental disorder that can significantly affect an individual's quality of life, making early diagnosis crucial for effective treatment. One non-invasive method to analyze brain activity is electroencephalography (EEG), particularly in the resting-state condition. This study aims to classify depressive conditions in individuals by utilizing Power Spectral Density (PSD) features extracted from EEG signals and processed using a Convolutional Neural Network (CNN). The EEG data were obtained from the MODMA dataset, recorded from eight selected EEG channels, and underwent pre-processing steps including filtering, time segmentation, and PSD feature extraction. Two CNN architectures were proposed, with Model 2 demonstrating better performance, achieving 99% accuracy, 1.00 precision in the depressive class, and 0.98 recall, compared to Model 1 with 98% accuracy. The results indicate that the combination of PSD and CNN can classify depressive conditions with high accuracy on resting-state datasets. However, the model's performance decreased on datasets with activate-state conditions, suggesting that future research should explore strategies to improve the model's generalization capability to more complex and dynamic data variations.

Keywords: Depression, EEG, Power Spectral Density, Convolutional Neural Network, Classification.

[Halaman ini sengaja dikosongkan]

KATA PENGANTAR

Puji dan syukur kehadiran Tuhan Yang Maha Esa, atas segala rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan penelitian ini yang berjudul **KLASIFIKASI DEPRESI MENGGUNAKAN CNN BERBASIS POWER SPECTRAL DENSITY PADA SINYAL EEG RESTING STATE**

Penelitian ini disusun dalam rangka pemenuhan Tugas Akhir sebagai syarat kelulusan Mahasiswa ITS. Oleh karena itu, penulis mengucapkan banyak terima kasih kepada Oleh karena itu, penulis mengucapkan terima kasih kepada:

1. Bapak Dr. Arief Kurniawan, S.T., M.T, selaku Kepala Departemen Teknik Komputer, Fakultas Teknologi Elektro dan Informatika Cerdas, Institut Teknologi Sepuluh Nopember.
2. Bapak Dr. Diah Puspito Wulandari, S.T., M.Sc.selaku Dosen Pembimbing I dan Ibu Dr. Eko Mulyanto Yuniarno, S.T., M.T.selaku Dosen Pembimbing II yang telah memberikan arahan dan membantu penulis selama pengerjaan tugas akhir ini.
3. Bapak-Ibu dosen pengajar Departemen Teknik Komputer, atas ilmu yang telah diberikan kepada penulis selama menjalani masa perkuliahan.
4. Kedua Orangtua, Adik, dan keluarga yang telah memberikan doa serta dukungan selama penulis mengenyam pendidikan.
5. Hamada Asahi dan Lee Dong-hyeok yang turut menemani, serta mendorong penulis selama menjalankan proses perkuliahan.
6. Teman - teman laboratorium Multimedia dan Internet Of Things (MIOT) yang membantu penulist dalam pengerjaan tugas akhir ini
7. Tidak lupa kepada teman - teman Teknik Komputer yang memberikan motivasi dan semangat selama masa perkuliahan.

Akhir kata, semoga penelitian ini dapat memberikan manfaat kepada banyak pihak. Penulis menyadari jika tugas akhir ini masih jauh dari kata sempurna. Untuk itu penulis mengharapkan saran dan kritik yang bersifat membangun untuk dapat menuai hasi yang lebih baik lagi.

Surabaya, Juli 2025

Mida Hasian

[Halaman ini sengaja dikosongkan]

DAFTAR ISI

ABSTRAK	i
ABSTRACT	iii
KATA PENGANTAR	v
DAFTAR ISI	vii
DAFTAR GAMBAR	ix
DAFTAR TABEL	xi
1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Tujuan	2
1.4 Batasan Masalah	2
1.5 Manfaat	2
2 TINJAUAN PUSTAKA	3
2.1 Depresi	3
2.2 <i>Electroencephalography</i> (EEG)	4
2.2.1 Sinyal EEG Resting State	5
2.2.2 Band Frekuensi EEG	5
2.3 <i>Power Spectral Density</i> (PSD)	6
2.3.1 Konsep Dasar PSD	6
2.4 Bandpass Filter	8
2.5 Segmentasi Waktu	9
2.5.1 Aplikasi pada Klasifikasi EEG	9
2.6 <i>Convolutional Neural Network</i> (CNN)	10
2.6.1 Dasar Teori CNN	10
2.6.2 Arsitektur CNN	11
3 METODOLOGI	15

3.1	Data	15
3.2	Seleksi Channel	16
3.3	Time Segmentation	18
3.4	Filterisasi Sinyal	18
3.5	<i>Power Spectral Density</i>	19
3.6	Input CNN	19
3.7	Pembuatan Model	20
4	PENGUJIAN DAN ANALISIS	25
4.1	Deskripsi Data EEG	25
4.2	Plot Time Segmenting	28
4.3	Filterisasi Sinyal	31
4.4	Hasil Power Spectral Density	34
4.5	Eksperimen	38
4.5.1	Model 1	38
4.5.2	Model 2	42
4.5.3	Rangkuman Pengujian Model	45
4.6	Pengujian Menggunakan Dataset Dot Probe	46
4.6.1	Model 1	46
4.6.2	Model 2	47
4.6.3	Pembahasan Hasil Pengujian Dataset Berbeda	48
5	PENUTUP	51
5.1	Kesimpulan	51
5.2	Saran	51
	DAFTAR PUSTAKA	53
	BIOGRAFI PENULIS	57

DAFTAR GAMBAR

2.1	Penempatan elektroda EEG berdasarkan sistem 10–20 [1]	4
2.2	Gambaran Rekam Resting State [2]	5
2.3	Ilustrasi Bandpass Filter [3]	8
2.4	Ilustrasi Time Segmenting [4]	9
2.5	Arsitektur CNN [5]	10
2.6	Ilustrasi Convolutional [6]	11
2.7	Ilustrasi ReLU [7]	12
2.8	Ilustrasi Pooling Layer [8]	13
2.9	Ilustrasi Classification [9]	14
3.1	Blok Diagram Penelitian	15
3.2	Letak channel yang dipilih [10]	17
3.3	Input CNN	20
3.4	Arsitektur CNN Model 1	21
3.5	Arsitektur CNN Model 2	23
4.1	Plot sinyal EEG mentah untuk channel F3, F4, C3, C4, P3, P4, O1, dan O2 pada kondisi sehat.	26
4.2	Plot sinyal EEG mentah untuk channel F3, F4, C3, C4, P3, P4, O1, dan O2 pada kondisi depresi.	27
4.3	Plot epoch pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi sehat.	29
4.4	Plot epoch pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi depresi.	30
4.5	Plot sinyal EEG setelah bandpass pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi sehat.	32
4.6	Plot sinyal EEG setelah bandpass pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi depresi.	33
4.7	Spektrogram PSD channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi sehat.	35
4.8	Spektrogram PSD channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi depresi.	37
4.9	Grafik Akurasi	39
4.10	Grafik Loss	39
4.11	Matrix Training Model 1	40
4.12	Matrix Validation Model 1	40
4.13	Matrix Testing Model 1	41

4.14	Grafik Akurasi dan Loss Model	42
4.15	Matrix Training Model 2	43
4.16	Matrix Validation Model 2	43
4.17	Matrix Testing Model 2	44
4.18	Matrix Predicted Model 1	47
4.19	Matrix Predicted Model 2	48

DAFTAR TABEL

4.1	Hasil Klasifikasi Model CNN 1	41
4.2	Hasil Nilai Validasi Model 1	41
4.3	Hasil Klasifikasi Model CNN 2	45
4.4	Hasil Nilai Validasi Model 2	45
4.5	Hasil Nilai Klasifikasi Model 1	47
4.6	Hasil Nilai Klasifikasi Model 2	48

[Halaman ini sengaja dikosongkan]

BAB I

PENDAHULUAN

1.1 Latar Belakang

Depresi, yang merupakan gangguan mental umum, ditandai oleh perasaan tertekan atau kehilangan minat dan kesenangan dalam berbagai aktivitas selama jangka waktu yang lama. Menurut data dari World Health Organization (WHO), sekitar 280 juta orang di seluruh dunia mengalami kondisi ini, dengan prevalensi yang 50% lebih tinggi pada wanita dibandingkan pria [11]. Gangguan ini dapat memengaruhi kehidupan sehari-hari seseorang, dan dalam kasus yang lebih serius, dapat memicu tindakan bunuh diri. Oleh karena itu, penting untuk melakukan diagnosis dini serta memberikan intervensi yang tepat untuk mengatasi depresi secara efektif.

Salah satu metode yang banyak digunakan dalam penelitian klinis untuk mendiagnosis kondisi psikologis adalah electroencephalography (EEG). Elektroensefalogram (EEG) merupakan instrumen yang digunakan untuk merekam aktivitas listrik di otak. Di bidang medis, EEG dimanfaatkan untuk mendiagnosis berbagai penyakit yang terkait dengan kelainan otak dan gangguan kejiwaan. Selain itu, aplikasi EEG yang lebih luas dapat digunakan untuk mendeteksi pola pikir dan kondisi mental seseorang [12]. Pada analisis ini, sinyal EEG dimanfaatkan untuk mempelajari aktivitas otak dalam kondisi resting state, yaitu ketika subjek dalam keadaan tenang tanpa adanya rangsangan eksternal.

Power Spectral Density (PSD) atau spektrum daya adalah metode yang mempermudah visualisasi distribusi frekuensi dari komponen-komponen sinyal, sehingga lebih mudah untuk dianalisis. PSD menunjukkan proporsi daya total sinyal yang berasal dari setiap komponen frekuensi dalam sinyal tegangan [13]. Metode ini memungkinkan identifikasi distribusi energi pada berbagai frekuensi dalam sinyal EEG, yang dapat memberikan informasi penting mengenai aktivitas otak individu yang mengalami depresi.

Untuk meningkatkan akurasi dalam klasifikasi depresi dari sinyal EEG, salah satu metode deep learning yang digunakan adalah Convolutional Neural Network (CNN). CNN adalah jenis jaringan saraf buatan yang sering diterapkan dalam deteksi dan pengenalan pola, karena memiliki keragaman fitur serta struktur yang cukup sederhana [14]. Metode ini memungkinkan identifikasi pola kompleks dalam data, sehingga sangat cocok untuk analisis sinyal EEG. Dengan menggunakan Power Spectral Density (PSD) sebagai input ke CNN, model ini diharapkan dapat mengklasifikasikan tingkat depresi dengan tepat, sehingga memberikan hasil yang akurat dalam mendeteksi kondisi depresi pada individu.

1.2 Rumusan Masalah

Adapun permasalahan yang akan dibahas pada penelitian ini sebagai berikut:

1. Menerapkan proses ekstraksi fitur Power Spectral Density (PSD) pada sinyal EEG.
2. Mengidentifikasi perbedaan antara individu yang mengalami depresi dengan individu normal melalui analisis Power Spectral Density (PSD).

1.3 Tujuan

Tujuan dari penelitian ini adalah sebagai berikut:

1. Melakukan ekstraksi fitur Power Spectral Density (PSD) dari sinyal EEG.
2. Mengidentifikasi kondisi depresi dengan memanfaatkan fitur Power Spectral Density (PSD) pada sinyal EEG menggunakan CNN.

1.4 Batasan Masalah

Untuk memfokuskan permasalahan yang diangkat maka diterapkan pembatasan penelitian. Batasan masalahnya adalah sebagai berikut:

1. Dataset yang digunakan dalam penelitian ini berasal dari MODMA (Multi-modal Open Dataset for Mental-disorder Analysis).
2. Metode Power Spectral Density (PSD) yang diterapkan adalah metode Fourier transform Channel yang digunakan adalah F3, F4, C3, C4, P3, P4, O1, dan O2.
3. Hasil penelitian akan mengklasifikasikan segmen-segmen sinyal EEG sebagai kondisi depresi atau tidak, tanpa membuat kesimpulan menyeluruh tentang kondisi individu pemilik sinyal tersebut.

1.5 Manfaat

Manfaat dari penelitian ini adalah pengembangan model neural network yang dapat membantu para peneliti, terutama di bidang medis dan psikologi, dalam mendeteksi dini kondisi depresi pada individu serta meningkatkan kesadaran (awareness) terhadap depresi.

BAB II

TINJAUAN PUSTAKA

Demi mendukung penelitian ini, dibutuhkan beberapa teori penunjang sebagai berikut

2.1 Depresi

Gangguan depresi adalah kondisi mental yang sangat umum, ditandai oleh suasana hati yang terus-menerus tertekan atau hilangnya ketertarikan dan kesenangan dalam berbagai aktivitas sehari-hari selama periode waktu yang panjang. Berbeda dengan fluktuasi suasana hati normal atau reaksi emosional singkat, depresi dapat mengganggu hampir setiap aspek kehidupan mulai dari hubungan keluarga dan pertemanan hingga kinerja di sekolah atau tempat kerja dan bisa menjadi penyebab maupun akibat dari masalah di berbagai bidang tersebut [11].

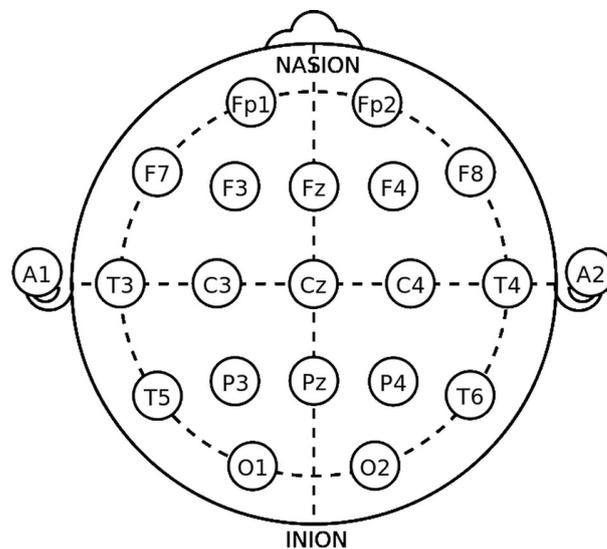
Depresi dapat menyerang siapa saja, dimana saja. Diperkirakan 3,8% populasi global mengalami depresi; di antara orang dewasa, angkanya mencapai 5%, sedangkan pada lansia di atas 60 tahun sekitar 5,7%. Secara total, sekitar 280 juta orang di dunia hidup dengan depresi. Insiden depresi pada wanita sekitar 50% lebih tinggi dibanding pria, dan lebih dari 10% wanita hamil atau pascapersalinan mengalami gejala depresi. Setiap tahun, lebih dari 700.000 jiwa hilang karena bunuh diri yang menempati urutan ke-4 penyebab kematian bagi usia 15–29 tahun—seringkali terkait dengan depresi berat [11].

Depresi umumnya berlangsung hampir sepanjang hari, selama minimal dua minggu, dan ditandai oleh perasaan sedih, mudah tersinggung, atau kekosongan emosional serta berkurangnya minat atau kesenangan dalam aktivitas yang biasanya menyenangkan. Selain gejala inti tersebut, penderitanya kerap mengalami gangguan konsentrasi, perasaan bersalah berlebihan atau rendah diri, rasa putus asa tentang masa depan, pikiran tentang kematian atau bunuh diri, gangguan tidur, perubahan nafsu makan atau berat badan, dan sangat rendahnya energi. Kondisi ini muncul dari interaksi kompleks antara faktor sosial, psikologis, dan biologis, di mana peristiwa hidup yang merugikan seperti kekerasan, kehilangan orang terdekat, pengangguran, atau trauma yang dimana dapat meningkatkan risiko terjadinya depresi. Meskipun telah tersedia terapi efektif, baik melalui psikoterapi maupun obat antidepresan, lebih dari 75% penderita di negara berpenghasilan rendah dan menengah masih belum mendapatkan perawatan yang memadai akibat terbatasnya dana, minimnya tenaga ahli, serta stigma sosial terhadap gangguan mental [11].

Depresi dapat disebabkan oleh berbagai faktor, termasuk faktor genetik, lingkungan, dan psikologis. Beberapa orang mungkin memiliki kecenderungan genetik untuk depresi, sementara yang lain dipicu oleh peristiwa stres seperti kehilangan orang yang dicintai atau masalah finansial. Pengalaman traumatis di masa kecil dan ketidakseimbangan kimiawi di otak juga berperan. Depresi bukanlah kelemahan pribadi dan membutuhkan pengobatan yang tepat, seperti terapi dan obat-obatan. Dukungan sosial, seperti berbicara dengan keluarga atau bergabung dengan kelompok dukungan.

2.2 Electroencephalography (EEG)

Electroencephalography (EEG) adalah teknik non-invasif yang merekam fluktuasi potensial listrik di korteks dengan menempatkan elektroda pada kulit kepala [15]. Perekaman EEG umum dilakukan selama 10–20 menit dengan aturan penempatan elektroda 10–20 untuk memastikan distribusi dan jarak yang konsisten antar channel [16]. Sinyal yang terekam mencakup rentang frekuensi 0,1–100 Hz dengan amplitudo mikrovolt. EEG memiliki resolusi temporal yang tinggi, yang memungkinkan respons cepat terhadap perubahan aktivitas otak [17]. Selain itu, EEG juga digunakan secara lebih luas untuk mengidentifikasi pola pikir atau kondisi mental seseorang [12]. Selain itu, EEG juga digunakan secara lebih luas untuk mengidentifikasi pola pikir atau kondisi mental seseorang [18]. Berikut merupakan letak penempatan aturan elektroda 10–20 pada Gambar 2.1

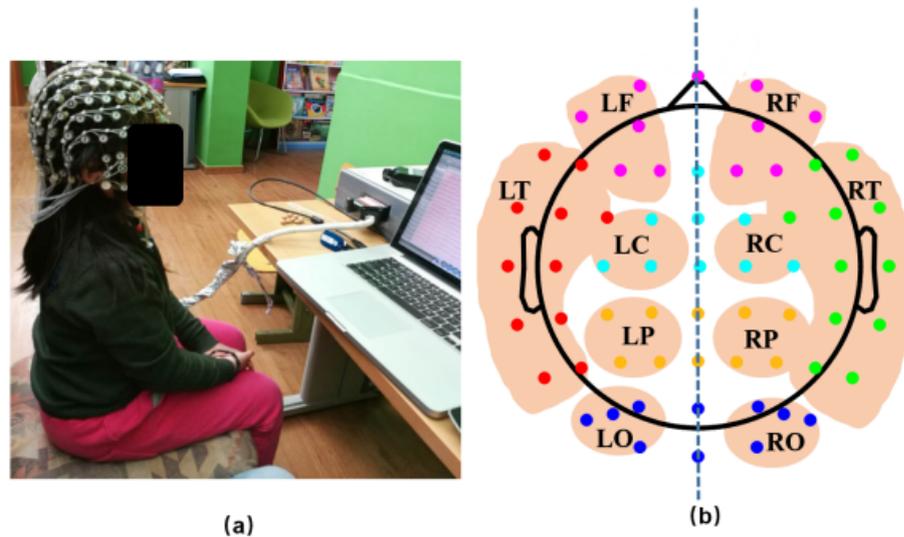


Gambar 2.1: Penempatan elektroda EEG berdasarkan sistem 10–20 [1]

Pada Gambar 2.1 menunjukkan bahwa penempatan elektroda tersebar mulai dari bagian depan, tengah, hingga belakang kepala. EEG memiliki banyak aplikasi dalam bidang kedokteran, terutama dalam diagnosis gangguan neurologis seperti epilepsi, gangguan tidur, dan gangguan mental lainnya. Sinyal EEG yang terekam dapat digunakan untuk memantau aktivitas otak secara langsung, memberikan informasi yang sangat berguna dalam perencanaan perawatan dan pengobatan. Selain itu, EEG juga digunakan dalam penelitian untuk memahami lebih lanjut tentang mekanisme dasar aktivitas otak dan bagaimana otak merespons berbagai rangsangan atau kondisi.

EEG semakin digunakan dalam bidang pengembangan dalam aplikasi psikologi untuk menilai kondisi mental, seperti stres, kecemasan, atau depresi. Teknologi ini memungkinkan interaksi langsung antara otak dan perangkat eksternal, membuka kemungkinan baru dalam rehabilitasi medis dan pengendalian perangkat menggunakan gelombang otak. Namun, untuk mencapai akurasi tinggi dalam interpretasi sinyal EEG, diperlukan pengolahan dan analisis sinyal yang cermat, yang dapat dilakukan menggunakan berbagai teknik pemrosesan sinyal dan machine learning.

2.2.1 Sinyal EEG Resting State



Gambar 2.2: Gambaran Rekam Resting State [2]

Pada protokol *resting-state*, subjek duduk rileks bisa dengan mata tertutup atau terbuka tanpa tugas kognitif khusus. Sinyal direkam selama 5–10 menit, kemudian dipotong menjadi epoch-epoch pendek untuk analisis lebih lanjut [18]. Keheningan relatif dan minimnya artefak sensorik menjadikan data resting state sebagai representasi stabil kondisi dasar otak, dimana gelombang alfa cenderung mendominasi saat mata tertutup.

Data resting state sangat berguna dalam penelitian neuroscience karena dapat menggambarkan pola dasar aktivitas otak tanpa gangguan dari tugas eksternal. Selain itu, sinyal EEG resting state juga sering digunakan untuk menganalisis konektivitas jaringan otak, karena pola gelombang yang tercatat mencerminkan komunikasi antara berbagai daerah otak yang terhubung. Sinyal EEG resting state juga digunakan untuk mendiagnosis gangguan neurologis dan mental. Misalnya, perubahan dalam pola gelombang otak dapat mengindikasikan adanya gangguan seperti depresi, kecemasan, atau gangguan tidur. Oleh karena itu, analisis sinyal EEG resting state telah menjadi alat penting dalam penelitian otak dan pengembangan terapi yang lebih tepat sasaran untuk gangguan otak.

2.2.2 Band Frekuensi EEG

Analisis spektral memisahkan sinyal EEG ke dalam beberapa pita frekuensi utama yang berkorelasi dengan fungsi otak berbeda [18]:

- **Delta (0,5–4 Hz):** dominan pada fase tidur dalam.
- **Theta (4–8 Hz):** terkait relaksasi ringan dan pemrosesan memori.
- **Alpha (8–13 Hz):** muncul saat keadaan rileks, terutama mata tertutup.
- **Beta (13–30 Hz):** berkaitan dengan kewaspadaan dan aktivitas kognitif.
- **Gamma (>30 Hz):** mencerminkan pemrosesan kognitif tingkat tinggi.

Dengan mengevaluasi distribusi daya di tiap pita frekuensi ini, peneliti dapat mengekstrak fitur otomatis untuk klasifikasi kondisi neurologis atau psikiatri misalnya deteksi depresi berdasarkan pola resting-state EEG [18].

Pemisahan sinyal EEG ke dalam band frekuensi ini memungkinkan analisis yang lebih mendalam mengenai keadaan fungsional otak. Setiap band frekuensi ini memberikan wawasan mengenai aktivitas otak dalam berbagai kondisi, baik saat beristirahat maupun dalam keadaan terjaga. Sebagai contoh, peningkatan aktivitas gelombang theta sering kali dikaitkan dengan keadaan relaksasi, sedangkan dominasi gelombang beta lebih terkait dengan keadaan terjaga dan aktivitas kognitif yang lebih intens. Penting untuk dicatat bahwa analisis band frekuensi ini tidak hanya terbatas pada penelitian dasar otak, tetapi juga sangat bermanfaat dalam konteks klinis. Misalnya, perubahan dalam rasio band frekuensi tertentu dapat menjadi indikator awal gangguan neurologis seperti epilepsi, depresi, atau gangguan kecemasan.

2.3 Power Spectral Density (PSD)

Power Spectral Density (PSD) adalah metode yang digunakan untuk mengamati distribusi daya atau energi sinyal EEG pada berbagai frekuensi selama periode waktu tertentu, yang memberikan wawasan penting mengenai aktivitas otak. Melalui analisis distribusi daya ini, kita dapat memahami bagaimana otak aktif pada frekuensi-frekuensi tertentu [19]. Metode matematika ini sangat bermanfaat dalam mendeteksi pola berulang dalam sinyal dan mengukur jumlah energi yang terkandung dalam pola tersebut, yang dilakukan dengan menganalisis frekuensi gelombang kompleks [20].

Analisis PSD memungkinkan untuk mengidentifikasi perubahan signifikan dalam aktivitas otak yang dapat berkaitan dengan berbagai kondisi neurologis. Dengan menggunakan PSD, peneliti dapat memantau pergeseran frekuensi ini yang berkaitan dengan perubahan dalam status mental atau penyakit tertentu. Selain itu, PSD juga sering digunakan untuk mempelajari dinamika otak dalam situasi tertentu, seperti saat melakukan tugas kognitif, atau bahkan untuk mendeteksi gangguan seperti epilepsi. Dengan memetakan distribusi daya pada frekuensi tertentu, kita dapat mendeteksi anomali atau pola yang mengarah pada diagnosis yang lebih tepat. Penggunaan PSD dalam analisis sinyal EEG semakin populer karena kemampuannya dalam memberikan gambaran yang lebih jelas tentang aktivitas otak pada tingkat frekuensi, yang sangat penting untuk aplikasi klinis dan penelitian neuroscience.

2.3.1 Konsep Dasar PSD

PSD mengukur kekuatan atau energi dari sinyal pada setiap frekuensinya. PSD diperoleh sebagai transformasi Fourier dari fungsi autokorelasi sinyal, sehingga menampilkan energi sinyal sebagai fungsi frekuensi. Pendekatan ini sangat cocok untuk sinyal stasioner dan rentang frekuensi sempit seperti osilasi EEG resting state, karena mampu mengungkap kontribusi daya tiap gelombang frekuensi. Dalam pipeline resting state EEG yang dipakai, PSD dihitung melalui fungsi `spectrogram` di SciPy, yang pada dasarnya menerapkan Short-Time Fourier Transform, dimana sinyal dibagi menjadi jendela sepanjang n sampel dengan overlap n sampel (Hann window), kemudian dihitung kuadrat modulus FFT pada tiap jendela untuk memperoleh matriks spektrum waktu frekuensi. Berikut persamaannya.

$$S_{xx}(f, t_k) = \left| \sum_{n=0}^{N-1} x[n + kH] w[n] e^{-j2\pi \frac{fn}{N}} \right|^2. \quad (2.1)$$

Dalam persamaan STFT, $x[n]$ merupakan sampel sinyal EEG; $N = \text{nperseg}$ menunjukkan panjang setiap segmen, sedangkan noverlap adalah jumlah overlap antar segmen sehingga hop size didefinisikan sebagai $H = N - \text{noverlap}$; $w[n]$ adalah fungsi jendela yang dipakai untuk mengurangi bocor spektral; faktor kompleks

$$e^{-j2\pi \frac{fn}{N}} \quad (2.2)$$

adalah kernel DFT yang memetakan data dari domain waktu ke domain frekuensi; waktu pusat segmen ke- k diberikan oleh $t_k = \frac{kH}{f_s}$ dimana f_s adalah laju sampling; dan frekuensi diskrit f dihitung sebagai

$$f = m \frac{f_s}{N}, \quad m = 0, 1, \dots, N - 1. \quad (2.3)$$

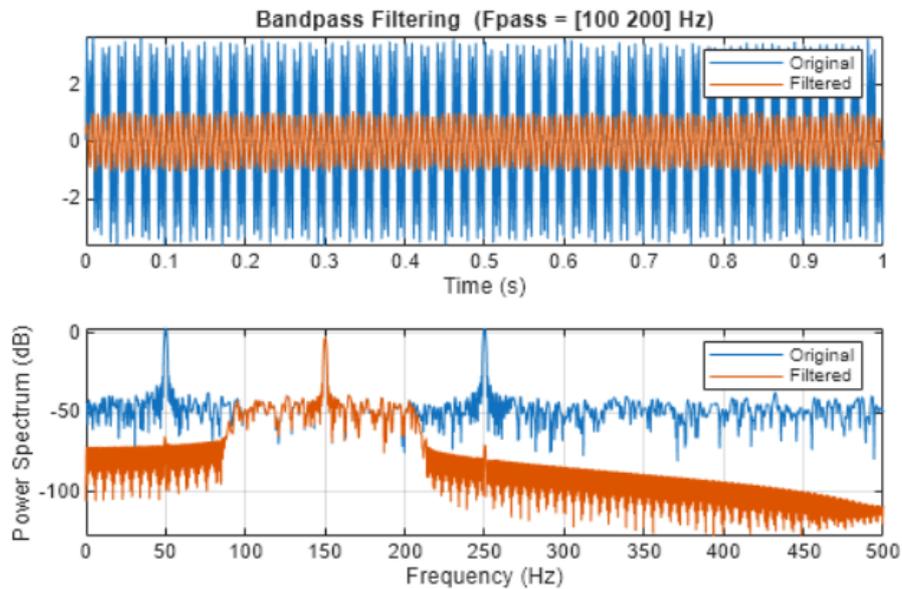
Untuk menstabilkan rentang dinamis, hasilnya di log-transform dengan persamaan berikut ini.

$$\hat{S}_{xx}(f, t_k) = \log(1 + S_{xx}(f, t_k)) \quad (2.4)$$

Menandakan bahwa setelah menghitung spektrum daya mentah $S_{xx}(f, t)$, melakukan transformasi logaritmik untuk meredam rentang dinamisnya. Penambahan konstanta 1 di dalam argumen logaritma memastikan bahwa nilai nol pada spektrum mentah tidak menyebabkan error (karena $\log(1 + 0) = 0$), sekaligus mempertahankan kontinuitas fungsi. Hasilnya, $\hat{S}_{xx}(f, t_k)$ menjadi representasi spektrum yang lebih seimbang, di mana puncak-puncak daya tinggi tidak terlalu menonjol dan komponen berdaya rendah tetap tersorot, sehingga mempermudah model CNN 2D dalam mengekstraksi pola frekuensi yang relevan.

Hasil transformasi logaritmik pada spektrum daya ini mempermudah model dalam memproses data dengan menstabilkan rentang daya spektral, sehingga mengurangi pengaruh nilai ekstrem yang dapat mengganggu kestabilan pelatihan. Hal ini memungkinkan model CNN 2D untuk lebih fokus pada pola frekuensi yang relevan tanpa terpengaruh oleh outlier atau puncak daya yang tidak signifikan. Transformasi logaritmik juga membantu meningkatkan generalisasi model, mengurangi overfitting terhadap fluktuasi daya yang tidak signifikan, dan memungkinkan model untuk menangkap variabilitas dalam aktivitas otak dengan lebih baik. Dengan representasi spektrum yang lebih seimbang, model dapat lebih efektif dalam mengklasifikasikan kondisi berdasarkan analisis frekuensi sinyal EEG, meningkatkan akurasi dalam diagnosis dan pemantauan kondisi mental.

2.4 Bandpass Filter



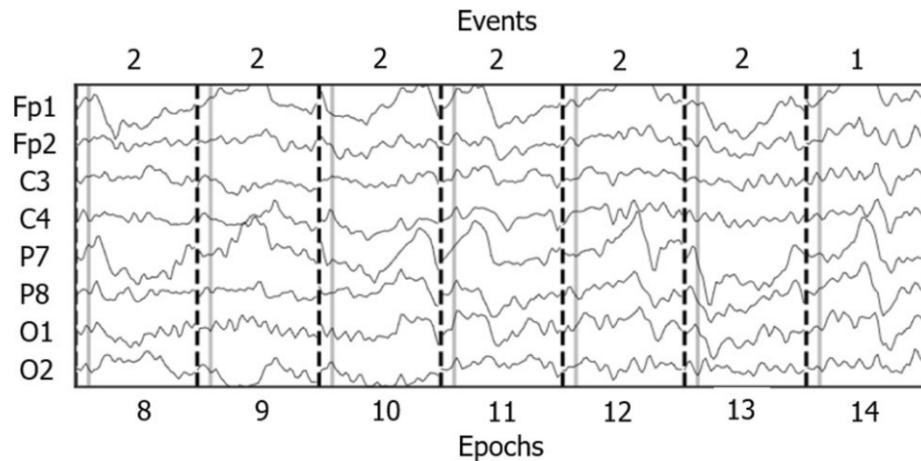
Gambar 2.3: Ilustrasi Bandpass Filter [3]

BPF (Bandpass Filter) adalah jenis filter yang hanya membiarkan sinyal melewati dalam rentang frekuensi tertentu, sementara sinyal di luar rentang tersebut akan ditekan. Filter ini memiliki dua frekuensi pemotongan, yaitu frekuensi pemotongan bawah (f_L) dan frekuensi pemotongan atas (f_H). Rentang antara kedua frekuensi pemotongan ini adalah area yang dilewatkan oleh filter, sedangkan sinyal di luar rentang frekuensi tersebut akan diredam [21]

Dengan menggunakan BPF, hanya sinyal dengan frekuensi yang berada di antara f_L dan f_H yang dapat diteruskan, sementara komponen frekuensi yang lebih rendah dari f_L dan lebih tinggi dari f_H akan diblokir atau diredam. Filter ini sangat berguna dalam berbagai aplikasi pengolahan sinyal, seperti pengolahan sinyal EEG, komunikasi, dan pengolahan audio, di mana hanya rentang frekuensi tertentu yang relevan untuk analisis lebih lanjut.

Penerapan BPF dapat meningkatkan kualitas data yang diinginkan dengan menghilangkan noise atau gangguan yang ada di luar rentang frekuensi yang relevan. Dalam pengolahan sinyal EEG, misalnya, BPF sering digunakan untuk mengisolasi gelombang otak tertentu, seperti gelombang alfa dan beta, yang berhubungan dengan aktivitas mental dan fisik. Dengan memfilter frekuensi yang tidak diinginkan, analisis data menjadi lebih akurat dan dapat memberikan wawasan yang lebih dalam mengenai kondisi otak atau fisiologis subjek. Selain itu, BPF juga berperan penting dalam meningkatkan efisiensi pemrosesan data, karena hanya informasi yang relevan yang diteruskan untuk analisis lebih lanjut, sementara data yang tidak relevan dibuang. Hal ini mengurangi beban komputasi dan memungkinkan model atau sistem pengolahan sinyal untuk berfokus pada elemen-elemen yang memiliki pengaruh signifikan terhadap hasil akhir. Dengan demikian, penggunaan BPF dalam berbagai aplikasi pengolahan sinyal, termasuk EEG, tidak hanya meningkatkan kualitas data tetapi juga mempercepat dan mempermudah proses analisis, sehingga menghasilkan temuan yang lebih akurat dan terpercaya.

2.5 Segmentasi Waktu



Gambar 2.4: Ilustrasi Time Segmenting [4]

Pengolahan data sinyal EEG dilakukan dengan membagi sinyal menjadi potongan-potongan berdasarkan waktu pada setiap gerakan yang telah direncanakan. Tujuan dari segmentasi ini adalah untuk mengelompokkan sinyal sesuai dengan waktu tertentu, sehingga proses pengolahan dapat dilakukan lebih cepat tanpa memerlukan waktu yang terlalu lama [22].

Segmentasi waktu ini juga memungkinkan model untuk lebih fokus pada perubahan aktivitas otak yang terjadi dalam periode tertentu, yang dapat membantu dalam mendeteksi gangguan atau pola yang relevan dalam kondisi depresi. Dengan membagi sinyal EEG menjadi potongan-potongan kecil, informasi yang lebih spesifik tentang pergerakan otak dan respons terhadap stimulus tertentu dapat dianalisis lebih mendalam, meningkatkan akurasi dalam pengolahan sinyal. Selain itu, segmentasi ini berkontribusi pada pengurangan beban komputasi dengan memecah sinyal besar menjadi bagian-bagian yang lebih kecil, sehingga mempercepat proses analisis dan memperkecil penggunaan sumber daya. Dengan demikian, segmentasi waktu tidak hanya meningkatkan efisiensi pemrosesan tetapi juga mempermudah identifikasi fitur-fitur yang signifikan dalam sinyal EEG untuk analisis lebih lanjut.

2.5.1 Aplikasi pada Klasifikasi EEG

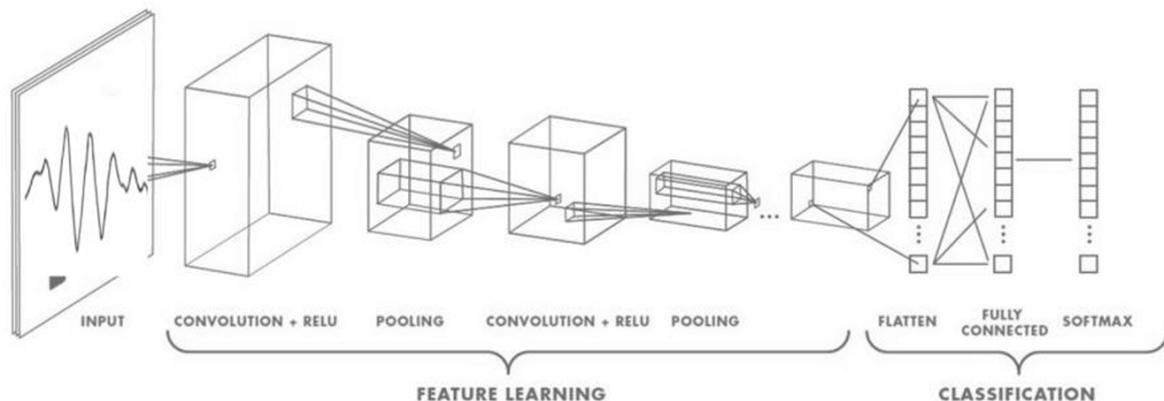
Dengan mengekstrak PSD sebagai representasi fitur, banyak penelitian berhasil mendeteksi kondisi neurologis atau psikiatri termasuk epilepsi dan depresi menggunakan model deep learning. Pada kasus depresi, variasi daya di band theta, alpha, dan beta pada area tertentu kerap muncul sebagai biomarker potensial. Representasi spektral yang dihasilkan melalui pendekatan Welch atau STFT ini memfasilitasi CNN dalam menangkap pola spasial temporal yang relevan untuk klasifikasi depresi.

Dengan kemampuannya untuk menangkap pola spasial temporal, CNN dapat secara otomatis mengekstraksi fitur penting dari sinyal EEG yang berkaitan dengan kondisi mental tertentu, seperti depresi. Melalui pelatihan yang mendalam, model-model ini mampu mengenali pola-pola yang tidak dapat dideteksi secara langsung oleh manusia, sehingga meningkatkan akurasi deteksi gangguan neurologis. Selain itu, teknik lain seperti transfer learning dan data augmentation telah digunakan untuk meningkatkan performa model dalam klasifikasi EEG. Transfer

learning memungkinkan model untuk memanfaatkan pengetahuan yang sudah ada dari dataset besar, sedangkan data augmentation memperkaya dataset dengan variasi sinyal EEG yang lebih luas, mengurangi kemungkinan overfitting dan meningkatkan kemampuan generalisasi model.

2.6 Convolutional Neural Network (CNN)

CNN (*Convolutional Neural Network*) adalah algoritma deep learning yang sangat efektif dalam mempelajari dan mengekstraksi fitur secara otomatis dengan struktur bertingkat. CNN mampu mengenali dan mengekstraksi fitur-fitur yang bergantung pada waktu dan ruang dari sinyal EEG, sehingga dapat meningkatkan akurasi dalam klasifikasi dan pengenalan sinyal EEG [23]. CNN terdiri dari beberapa lapisan dengan fungsi khusus, seperti lapisan konvolusi (*convolution layer*), lapisan terhubung penuh (*fully-connected layer*), dan lapisan pengambilan sampel (*pooling layer*) [14]. Berikut Gambar 2.5 arsitektur dari CNN.



Gambar 2.5: Arsitektur CNN [5]

Kelebihan utama dari CNN adalah kemampuannya dalam melakukan ekstraksi fitur otomatis dari data mentah tanpa memerlukan pra-pemrosesan fitur secara manual. Hal ini sangat berguna dalam aplikasi-aplikasi seperti klasifikasi sinyal EEG, di mana pola-pola yang relevan dapat ditemukan dalam data tanpa memerlukan intervensi manusia. Dengan kombinasi dari berbagai lapisan ini, CNN dapat mempelajari representasi hierarkis dari data, yang menjadikannya sangat efektif untuk tugas-tugas pengenalan pola dan klasifikasi dalam berbagai domain, termasuk pengolahan sinyal EEG untuk deteksi kondisi neurologis.

2.6.1 Dasar Teori CNN

CNN terinspirasi dari cara otak manusia memproses informasi visual, sehingga memungkinkan komputer untuk “melihat” dan membedakan objek proses yang dikenal sebagai pengenalan citra. Secara teknis, CNN adalah teknik klasifikasi dalam ranah deep learning yang memanfaatkan lapisan konvolusi untuk menerapkan filter pada data masukan dan mengekstrak ciri spasial. Meskipun struktur dasarnya mirip dengan jaringan saraf tiruan konvensional dengan unit-unit yang memiliki bobot, bias, dan fungsi aktivasi CNN menggunakan dua tahap utama: fase pelatihan yang dijalankan melalui *backpropagation*, dan klasifikasi yang dilakukan lewat *forward propagation*.

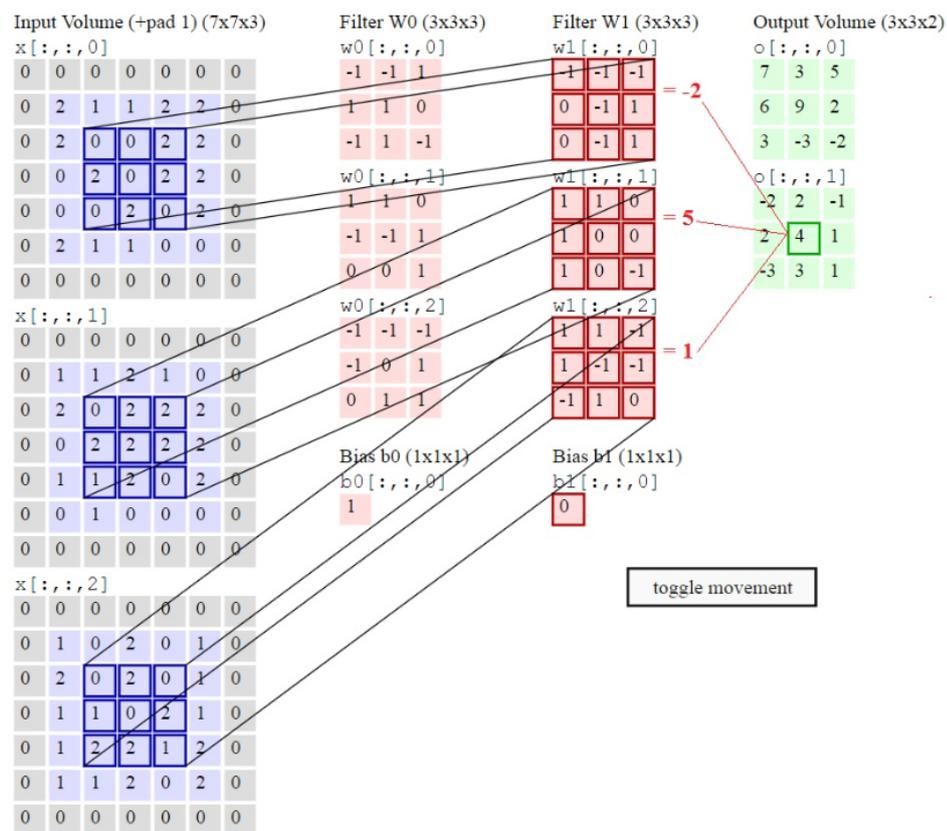
Pada fase pelatihan, CNN melakukan pembaruan bobot dengan cara meminimalkan fungsi kerugian melalui algoritma *backpropagation*, yang mengukur selisih antara output prediksi dan

nilai target yang diinginkan. Selama proses ini, gradien dihitung dan digunakan untuk menyesuaikan bobot filter agar dapat mengidentifikasi fitur yang lebih relevan dalam data masukan. Proses ini diulang hingga model mencapai tingkat akurasi yang diinginkan. Setelah tahap pelatihan, CNN dapat digunakan untuk klasifikasi data baru melalui *forward propagation*, di mana data input melewati lapisan-lapisan CNN yang telah dilatih. Dalam fase ini, fitur yang telah dipelajari sebelumnya digunakan untuk membuat prediksi tentang kelas atau kategori data.

2.6.2 Arsitektur CNN

CNN terdiri dari beberapa lapisan utama yang berfungsi untuk mengekstraksi fitur dari input, kemudian melakukan klasifikasi berdasarkan fitur-fitur tersebut [24]. Arsitektur CNN bekerja dengan cara menerapkan serangkaian operasi pada data input untuk mengidentifikasi pola atau fitur yang relevan. Dengan menggunakan lapisan-lapisan ini, CNN dapat mengenali dan mengklasifikasikan data dengan tingkat akurasi yang tinggi, menjadikannya sangat efektif dalam aplikasi-aplikasi seperti pengolahan gambar, analisis sinyal, dan pengenalan pola. Berikut penjelasan mengenai tahapan klasifikasi yang dilakukan menggunakan CNN:

2.6.2.1 Convolutional Layer



Gambar 2.6: Ilustrasi Convolutional [6]

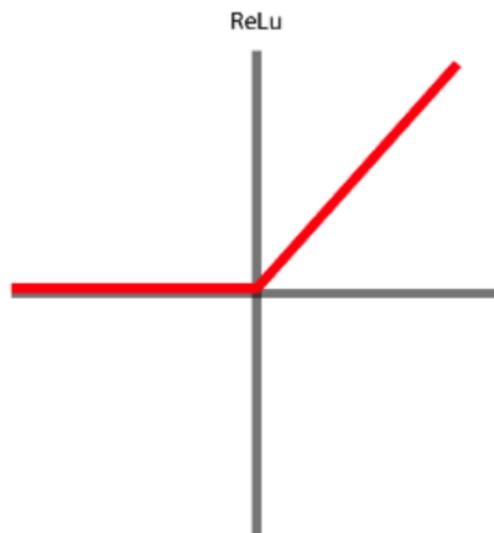
Dalam lapisan konvolusi, operasi konvolusi menerapkan sekumpulan filter (kernel) pada input baik citra maupun sinyal dengan menggeser kernel melintasi data untuk menghasilkan feature map yang menyorot pola seperti tepi, sudut, atau tekstur [24]. Perpindahan ini diatur oleh parameter stride, misalnya stride=1 membuat kernel bergeser satu piksel ke kanan lalu

satu piksel ke bawah setiap langkah, sehingga overlap kernel yang lebih kecil (stride rendah) memungkinkan deteksi fitur yang lebih halus. Sementara itu, padding menambahkan baris dan kolom nol di sekeliling data input agar dimensi output tetap sama dengan input, sehingga fitur di tepi citra pun dapat terekstraksi sempurna [5]. Dengan kombinasi konvolusi, stride, dan padding, lapisan ini secara otomatis mempelajari filter optimal untuk mengekstrak ciri spasial sebuah fondasi penting sebelum diteruskan ke lapisan aktivasi dan pooling.

Proses konvolusi ini memungkinkan model untuk mendeteksi pola hierarkis yang semakin kompleks pada setiap lapisan. Pada lapisan awal, model cenderung mendeteksi fitur sederhana seperti garis dan tepi, yang kemudian digabungkan pada lapisan-lapisan berikutnya untuk membentuk pola yang lebih kompleks, seperti bentuk atau tekstur yang lebih spesifik. Kemampuan ini membuat jaringan saraf konvolusional sangat efisien dalam mengenali pola-pola.

Salah satu keuntungan utama dari penggunaan lapisan konvolusi adalah parameter yang dibagi di seluruh input, yang memungkinkan model untuk belajar dengan jumlah parameter yang jauh lebih sedikit dibandingkan dengan model jaringan saraf penuh. Hal ini membantu dalam mengurangi kompleksitas model dan risiko overfitting, serta memungkinkan model untuk bekerja lebih efisien pada dataset besar.

2.6.2.2 Activation Function



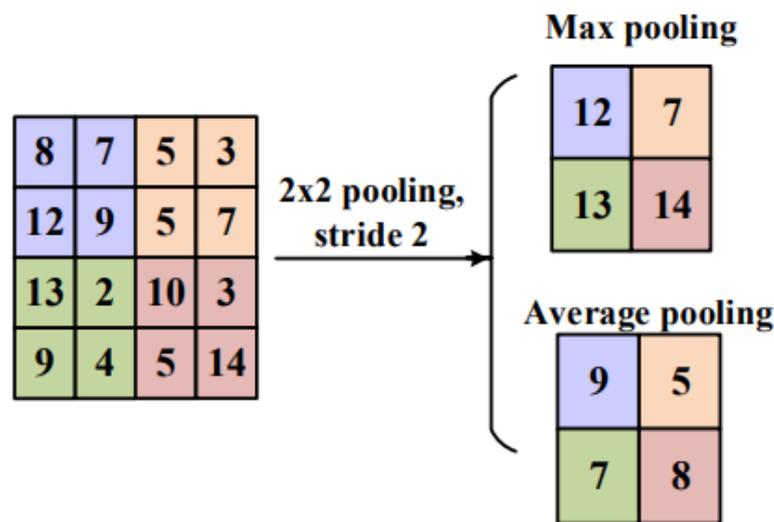
Gambar 2.7: Ilustrasi ReLU [7]

Fungsi aktivasi adalah komponen nonlinier yang ditambahkan sesaat setelah output dari tiap lapisan jaringan saraf untuk memroses feature map terakhir dan mengekstrak pola yang kompleks. Dalam arsitektur CNN, fungsi ini ditempatkan setelah lapisan konvolusi dan terkadang pooling untuk memperkenalkan non-linearitas ke dalam model. Beberapa fungsi aktivasi yang umum digunakan meliputi sigmoid, tanh, Rectified Linear Unit (ReLU), Leaky ReLU (LReLU), dan Parametric ReLU [5]. ReLU (Rectified Linear Unit) adalah fungsi aktivasi yang membatasi output lapisan sebelumnya dengan mengubah setiap nilai negatif menjadi nol, sekaligus mempertahankan nilai positif apa adanya. Pemetaan ini membantu mempercepat proses pelatihan jaringan [24].

Selain itu, fungsi aktivasi ReLU memiliki kelebihan dalam hal kesederhanaan dan efektivitas

tas, sehingga sering digunakan dalam berbagai jenis jaringan saraf, termasuk CNN. Keunggulan lainnya adalah kemampuannya dalam mengurangi masalah vanishing gradient yang sering terjadi pada fungsi aktivasi lain seperti sigmoid dan tanh. Namun, ReLU juga memiliki kelemahan, yaitu masalah *dead neurons*, di mana unit-unit tertentu berhenti memperbarui bobotnya selama pelatihan karena outputnya selalu nol. Untuk mengatasi kekurangan tersebut, beberapa varian ReLU telah dikembangkan, seperti Leaky ReLU dan Parametric ReLU, yang memungkinkan sebagian kecil nilai negatif diteruskan melalui fungsi aktivasi. Hal ini membantu mencegah neuron mati dan memungkinkan pelatihan model yang lebih stabil dan efektif. Penggunaan fungsi aktivasi yang tepat dapat meningkatkan kinerja model CNN, terutama dalam tugas-tugas yang memerlukan pemrosesan data kompleks, seperti klasifikasi gambar dan deteksi objek.

2.6.2.3 Pooling Layer



Gambar 2.8: Ilustrasi Pooling Layer [8]

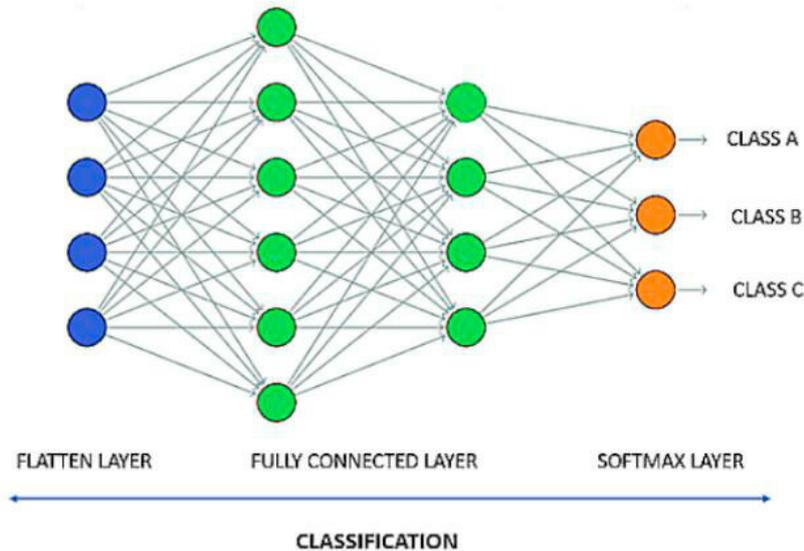
Lapisan ini menerima *feature map* sebagai input dan menerapkan statistik lokal umumnya *max pooling*—untuk mereduksi dimensi spasialnya. Lapisan ini biasanya disisipkan setelah satu atau beberapa lapisan konvolusi, dan secara bertahap mengecilkan ukuran volume output. Dengan demikian, jumlah parameter dan beban komputasi berkurang, pelatihan menjadi lebih cepat, dan risiko *overfitting* menurun. Pada *max pooling*, peta fitur dibagi ke dalam kotak-kotak kecil (grid) yang tidak saling tumpang-tindih, lalu dari setiap kotak diambil nilai piksel tertinggi untuk membentuk output *ter-pooling* [5].

Meskipun *max pooling* sering digunakan, terdapat varian lain dari pooling seperti *average pooling* yang menggantikan nilai maksimum dengan nilai rata-rata dari piksel-piksel dalam kotak yang sama. Meskipun kedua teknik ini memiliki tujuan yang serupa, yaitu untuk mereduksi dimensi dan mengurangi komputasi, *max pooling* cenderung lebih baik dalam mempertahankan fitur penting, sementara *average pooling* lebih cocok untuk tugas yang membutuhkan pemrosesan yang lebih halus dan pengurangan noise.

Selain itu, ukuran jendela pooling dan langkah (stride) adalah parameter penting yang dapat mempengaruhi kinerja model. Jendela yang lebih kecil memungkinkan detail yang lebih halus untuk dipertahankan, tetapi dapat menghasilkan lebih banyak parameter, sedangkan jendela yang lebih besar dapat menyebabkan hilangnya informasi lokal yang penting. Oleh karena

itu, pemilihan ukuran jendela dan langkah yang optimal sangat bergantung pada jenis tugas yang dihadapi.

2.6.2.4 Classification Layer



Gambar 2.9: Ilustrasi Classification [9]

Setelah fitur berhasil diekstraksi, tahap berikutnya dalam arsitektur CNN adalah lapisan klasifikasi, yang terdiri dari beberapa yaitu ada Lapisan **Flatten** mengubah peta fitur multidimensi menjadi vektor satu dimensi sehingga dapat diproses oleh lapisan selanjutnya. Lapisan **Fully Connected (Dense)** kemudian menghubungkan setiap elemen vektor tersebut ke seluruh neuron pada lapisan akhir, mirip dengan Multilayer Perceptron (jaringan saraf tiruan konvensional). Akhirnya, fungsi aktivasi **Softmax** mengubah output menjadi distribusi probabilitas di rentang $[0, 1]$ untuk setiap kelas, dengan total probabilitas sama dengan 1, sehingga cocok untuk tugas klasifikasi multikelas [24].

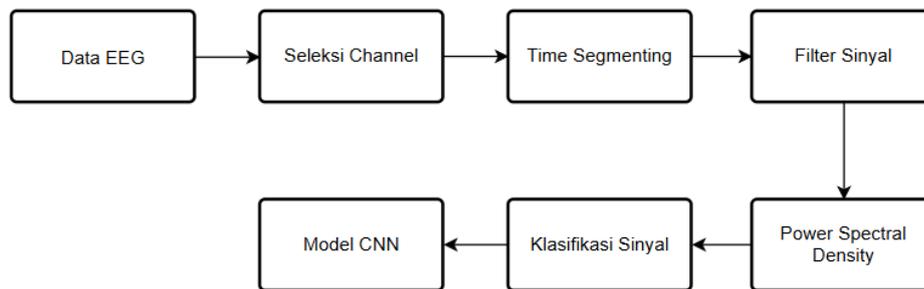
Setelah tahap klasifikasi, model dapat menghasilkan hasil yang menunjukkan kemungkinan prediksi untuk setiap kelas yang ada. Dalam kasus klasifikasi multikelas, **Softmax** memastikan bahwa nilai output untuk setiap kelas berada dalam rentang $[0, 1]$ dan jumlah total probabilitas untuk semua kelas adalah 1, yang memungkinkan interpretasi hasil sebagai probabilitas prediksi untuk masing-masing kelas. Hal ini memungkinkan model untuk memilih kelas dengan probabilitas tertinggi sebagai prediksi akhir.

Namun, meskipun **Softmax** adalah pilihan yang umum untuk klasifikasi multikelas, dalam beberapa kasus, terutama untuk tugas biner, fungsi aktivasi **Sigmoid** lebih sering digunakan. Pada tugas klasifikasi dua kelas, **Sigmoid** memberikan probabilitas untuk masing-masing kelas, memungkinkan model untuk menghasilkan dua probabilitas dan memilih kelas dengan probabilitas tertinggi. Pemilihan fungsi aktivasi yang tepat sangat bergantung pada jenis masalah klasifikasi yang dihadapi, dengan pertimbangan untuk memilih fungsi yang paling sesuai dengan kebutuhan aplikasi dan dataset yang tersedia.

BAB III

METODOLOGI

Desain dan implementasi dimulai dari perolehan sumber data, diikuti oleh pengolahan data, kemudian pengembangan model CNN, dan diakhiri dengan analisis hasil pengujian model terkait. Berikut diagram pada Gambar 3.1.



Gambar 3.1: Blok Diagram Penelitian

Diagram alur penelitian ini dimulai dengan pengumpulan data EEG, yang kemudian dilanjutkan dengan seleksi channel untuk memilih saluran-saluran EEG yang relevan. Data yang telah dipilih dibagi menjadi segmen-segmen waktu melalui time segmenting dan kemudian difilter untuk menghilangkan noise pada tahap filter sinyal. Setelah itu, dilakukan perhitungan Power Spectral Density (PSD) untuk menganalisis distribusi daya dalam domain frekuensi. Hasil pemrosesan ini digunakan untuk klasifikasi sinyal, yang mengkategorikan sinyal EEG berdasarkan pola yang terdeteksi, seperti depresi atau gangguan lainnya. Tahap terakhir melibatkan penerapan model CNN untuk mengekstrak fitur dan melakukan klasifikasi berdasarkan pola yang ditemukan, menghasilkan analisis yang lebih akurat.

3.1 Data

Data yang digunakan dalam penelitian ini berasal dari perekaman sinyal EEG yang diperoleh melalui dataset publik. Perekaman dilakukan pada 53 partisipan, yang terdiri dari 24 pasien dengan depresi dan 29 individu sehat. Semua partisipan memiliki penglihatan yang normal atau dinilai normal. Pasien dengan depresi MDD (major depressive disorder) direkrut dari pasien rawat inap dan rawat jalan di Rumah Sakit Kedua Universitas Lanzhou, Gansu, Cina, atas rekomendasi dan diagnosis dari psikiater klinis. Seluruh pasien MDD menjalani Mini-International Neuropsychiatric Interview (MINI) yang memenuhi kriteria diagnostik MDD berdasarkan Diagnostic and Statistical Manual of Mental Disorders (DSM) versi DSM-IV.

Kriteria inklusi untuk semua partisipan mencakup usia antara 18 hingga 55 tahun serta tingkat pendidikan minimal pendidikan dasar. Khusus untuk pasien MDD, kriteria tambahan adalah memenuhi standar diagnostik MINI untuk depresi, memiliki skor minimal 5 pada Patient

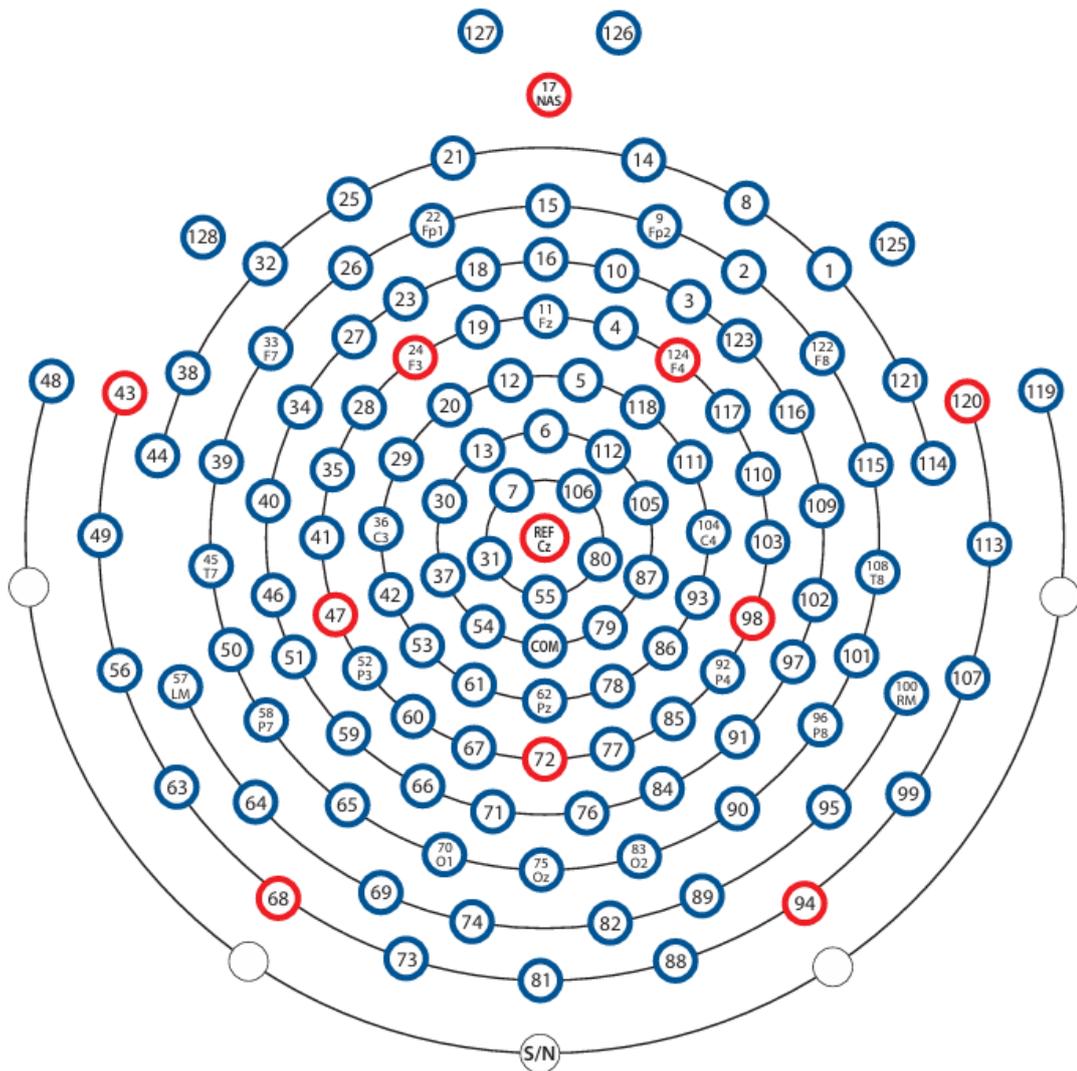
Health Questionnaire 9-item (PHQ-9), serta tidak menerima pengobatan psikotropika dalam dua minggu terakhir. Kriteria eksklusi untuk pasien MDD meliputi adanya gangguan mental atau kerusakan organ otak lainnya, penyakit fisik yang serius, serta kecenderungan bunuh diri yang parah. Sedangkan untuk kelompok kontrol (NC), kriteria eksklusi termasuk riwayat pribadi atau keluarga dengan gangguan mental. Kriteria eksklusi umum untuk semua partisipan adalah penyalahgunaan atau ketergantungan alkohol atau obat psikotropika dalam satu tahun terakhir, kehamilan atau menyusui, dan penggunaan pil kontrasepsi.

Data EEG multi-saluran dikumpulkan di ruangan yang tenang, kedap suara, dan memiliki ventilasi yang baik tanpa adanya gangguan elektromagnetik kuat. Partisipan menjalankan tugas dengan duduk sendiri di ruangan tersebut, sementara operator memantau dari ruangan sebelah. Setelah pemasangan elektroda selesai dan impedansi memenuhi standar, proses perekaman dimulai.

Perekaman berlangsung selama 5 menit dalam kondisi resting state dengan menggunakan HydroCel Geodesic Sensor Net 128-channel, dengan laju sampling sebesar 250 Hz. Data EEG dalam kondisi resting state dengan mata tertutup direkam selama 5 menit. Peserta diminta untuk tetap terjaga dan diam tanpa melakukan gerakan tubuh, termasuk kepala dan kaki, serta menghindari gerakan mata yang tidak perlu, seperti saccades dan kedipan. Data hasil perekaman kemudian dimuat menggunakan EEGLAB toolbox di MATLAB untuk diekspor dalam format .mat, menghasilkan total 129 channel dari elektroda E1 hingga E128 sesuai dengan perangkat yang digunakan [25]

3.2 Seleksi Channel

Berikut adalah letak dari channel eeg yang dipilih pada Gambar 3.2.



Gambar 3.2: Letak channel yang dipilih [10]

Penelitian ini menggunakan area frontal, sentral, parietal, dan oksipital. Channel yang digunakan F3(24), F4(124), C3(36), C4(104), P3(52), P4(92), O1(70), dan O2(83). F3 dan F4 berhubungan dengan pengaturan mood dan emosi, yang sangat penting dalam mendeteksi depresi. P3 dan P4 terkait dengan pemrosesan sensorik dan perhatian, yang bisa menunjukkan gangguan kognitif pada depresi. C3 dan C4 berkaitan dengan pemrosesan motorik dan sensorik, yang sering terpengaruh pada individu dengan depresi. O1 dan O2 berfungsi untuk memonitor aktivitas gelombang visual, yang bisa terganggu oleh masalah tidur pada penderita depresi. Pemilihan channel ini membantu dalam mengidentifikasi perbedaan pola aktivitas otak antara individu sehat dan depresi.

Seleksi channel ini didasarkan pada relevansi fungsional masing-masing area otak yang terlibat dalam pengaturan emosi, kognisi, serta pemrosesan motorik dan sensorik, yang semuanya dapat terpengaruh oleh kondisi depresi. Selain itu, pemilihan channel ini mempertimbangkan penelitian-penelitian terdahulu yang menunjukkan bahwa area-area tersebut memiliki hubungan erat dengan gejala depresi, sehingga menjadi fokus utama dalam analisis sinyal EEG.

Dengan memilih saluran yang tepat, penelitian ini bertujuan untuk memperoleh data yang lebih representatif dan relevan dalam mengidentifikasi perbedaan aktivitas otak antara individu yang sehat dan yang mengalami depresi. Melalui seleksi channel yang cermat ini, penelitian diharapkan dapat memberikan wawasan lebih dalam mengenai mekanisme otak yang terlibat dalam depresi, serta menghasilkan hasil analisis yang lebih akurat. Penggunaan channel-channel ini memungkinkan identifikasi fitur-fitur yang signifikan dalam sinyal EEG, yang dapat digunakan untuk meningkatkan performa model klasifikasi dalam mendiagnosis depresi.

3.3 Time Segmentation

Proses segmentasi waktu dalam penelitian ini membagi sinyal EEG yang sudah difilter menjadi potongan-potongan kecil yang masing-masing berdurasi 6 detik dengan tumpang tindih 50%. Setiap potongan (epoch) kemudian dianalisis secara terpisah, memungkinkan model untuk menangkap variasi dan pola aktivitas otak secara lebih detail. Setelah semua epoch dipotong, array dari epoch-epoch tersebut disusun ke dalam sebuah array 3D dengan dimensi $[n_{\text{epochs}}, n_{\text{channels}}, \text{samples_per_epoch}]$, di mana n_{epochs} adalah jumlah total epoch yang dihasilkan, n_{channels} adalah jumlah kanal yang dipilih, dan samples_per_epoch adalah jumlah sampel dalam setiap epoch. Dengan cara ini, model dapat lebih mudah membedakan antara kondisi sehat dan depresi, yang pada akhirnya dapat meningkatkan akurasi dalam mengklasifikasikan kondisi tersebut.

Segmentasi waktu ini memungkinkan analisis yang lebih mendalam terhadap sinyal EEG, karena model dapat memfokuskan perhatian pada variasi temporal yang mungkin tidak terdeteksi jika seluruh sinyal dianalisis secara keseluruhan. Dengan membagi sinyal menjadi epoch yang lebih kecil, model dapat menangkap perubahan yang lebih cepat dalam aktivitas otak, yang sangat penting dalam mendeteksi gejala depresi yang mungkin terjadi dalam jangka waktu singkat. Selain itu, teknik segmentasi waktu dengan tumpang tindih 50% membantu memastikan bahwa informasi yang mungkin hilang di antara batas epoch tidak terabaikan. Proses ini meningkatkan kontinuitas informasi yang digunakan oleh model, sehingga dapat mengidentifikasi pola-pola lebih halus dalam data. Dengan demikian, segmentasi waktu tidak hanya meningkatkan efisiensi pemrosesan data, tetapi juga berkontribusi pada akurasi hasil klasifikasi kondisi otak, khususnya dalam membedakan antara individu sehat dan yang mengalami depresi.

3.4 Filterisasi Sinyal

Proses filterisasi menggunakan filter Butterworth band-pass membantu untuk menghilangkan komponen frekuensi yang tidak relevan (seperti noise dan artefak) dari sinyal EEG. Rentang frekuensi yang diteruskan—0.1 Hz hingga 40 Hz—mencakup gelombang otak yang relevan untuk analisis depresi, sehingga sinyal yang telah difilter lebih stabil. Filterisasi sinyal dilakukan pada setiap channel yang telah dipilih sebelumnya dalam sinyal EEG tersebut.

Proses filterisasi ini penting untuk memastikan bahwa hanya frekuensi yang relevan dengan kondisi otak yang dipertahankan, sementara komponen-komponen lain yang dapat mengganggu analisis, seperti noise atau artefak, dihilangkan. Dengan rentang frekuensi yang telah ditentukan, sinyal EEG yang telah difilter akan menunjukkan gambaran aktivitas otak yang lebih jelas, terutama yang berkaitan dengan gelombang otak yang terlibat dalam keadaan depresi.

Setelah filterisasi, sinyal yang telah diproses akan lebih mudah dianalisis untuk mendeteksi pola-pola yang menunjukkan adanya perbedaan antara individu yang sehat dan yang mengalami

depresi. Dengan menghilangkan komponen yang tidak relevan, model yang dibangun untuk klasifikasi kondisi depresi akan bekerja lebih efisien dan akurat dalam mengidentifikasi gejala-gejala yang ada pada data EEG.

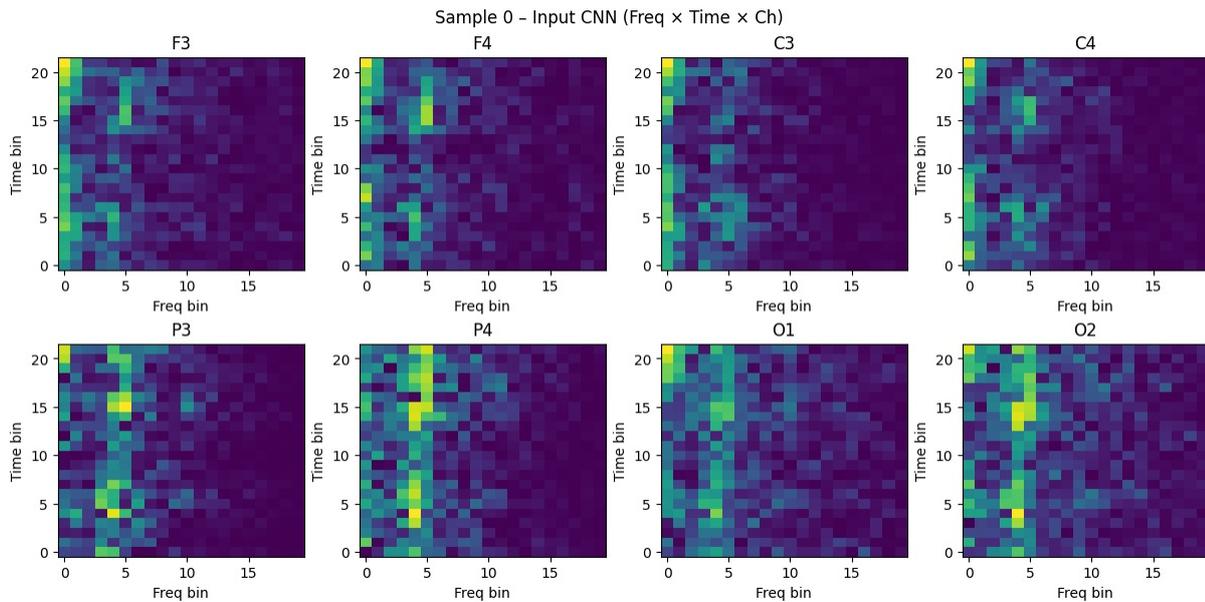
3.5 Power Spectral Density

Pada setiap epoch yang telah difilter, spektrum waktu-frekuensi dihitung dengan menerapkan Short-Time Fourier Transform (STFT) menggunakan fungsi `spectrogram`—window sepanjang 128 sampel dan overlap 64 sampel sehingga diperoleh matriks daya spektral S_{xx} berukuran $[n_{\text{freq_bins}}, n_{\text{time_bins}}]$, di mana setiap elemen menunjukkan kuadrat magnitudo Fourier Transform pada frekuensi dan waktu tertentu. Selanjutnya, untuk hanya mempertahankan rentang frekuensi EEG yang relevan, baris-baris frekuensi di luar rentang 0,1–40 Hz disingkirkan sehingga terbentuk S_{xx_masked} yang kemudian dikompres secara logaritmik melalui persamaan 2.2. Langkah ini mereduksi perbedaan nilai ekstrem dan menstabilkan distribusi daya spektral. Akhirnya, semua matriks `PSD_log` dari setiap kanal dan setiap epoch digabung menjadi array empat dimensi berukuran $[n_{\text{epochs}}, n_{\text{channels}}, n_{\text{freq_bins}}, n_{\text{time_bins}}]$ dan kemudian ditranspose menjadi tensor $[n_{\text{samples}}, n_{\text{freq_bins}}, n_{\text{time_bins}}, n_{\text{channels}}]$, yang siap digunakan sebagai input pada CNN.

Langkah-langkah tersebut memastikan bahwa data yang dihasilkan memiliki format yang sesuai untuk digunakan dalam model Convolutional Neural Network (CNN). Dengan memanfaatkan transformasi Fourier dan pemrosesan logaritmik, distribusi daya spektral dari sinyal EEG dapat lebih mudah dianalisis dan dipelajari oleh model. Proses ini memungkinkan model untuk mengidentifikasi pola frekuensi yang relevan dengan kondisi mental, seperti depresi, dengan lebih efektif. Penggunaan tensor empat dimensi ini juga memberikan fleksibilitas dalam menangani data yang kompleks dan besar, karena setiap dimensi mewakili elemen-elemen penting dalam sinyal EEG, seperti epoch, channel, frekuensi, dan waktu. Dengan format ini, model CNN dapat secara efisien memproses dan mengeksplorasi fitur-fitur temporal dan frekuensial dari sinyal EEG, yang sangat berguna dalam membedakan kondisi sehat dan depresi berdasarkan pola aktivitas otak.

3.6 Input CNN

Hasil komputasi `PSDlog` untuk setiap epoch dan channel kemudian digabungkan menjadi satu tensor tiga dimensi yang selanjutnya menjadi input model CNN. Berdasarkan parameter `nperseg=128`, `noverlap=64`, dan rentang frekuensi 0,1–40 Hz, diperoleh 20 bin frekuensi ($n_{\text{freq}} = 20$) dan 22 frame waktu ($n_{\text{time}} = 22$), sedangkan jumlah channel EEG yang digunakan adalah $n_{\text{channel}} = 8$. Dengan demikian, ukuran input CNN dalam penelitian ini adalah $20 \times 22 \times 8$. Representasi input ini divisualisasikan pada Gambar 3.3 di bawah ini.

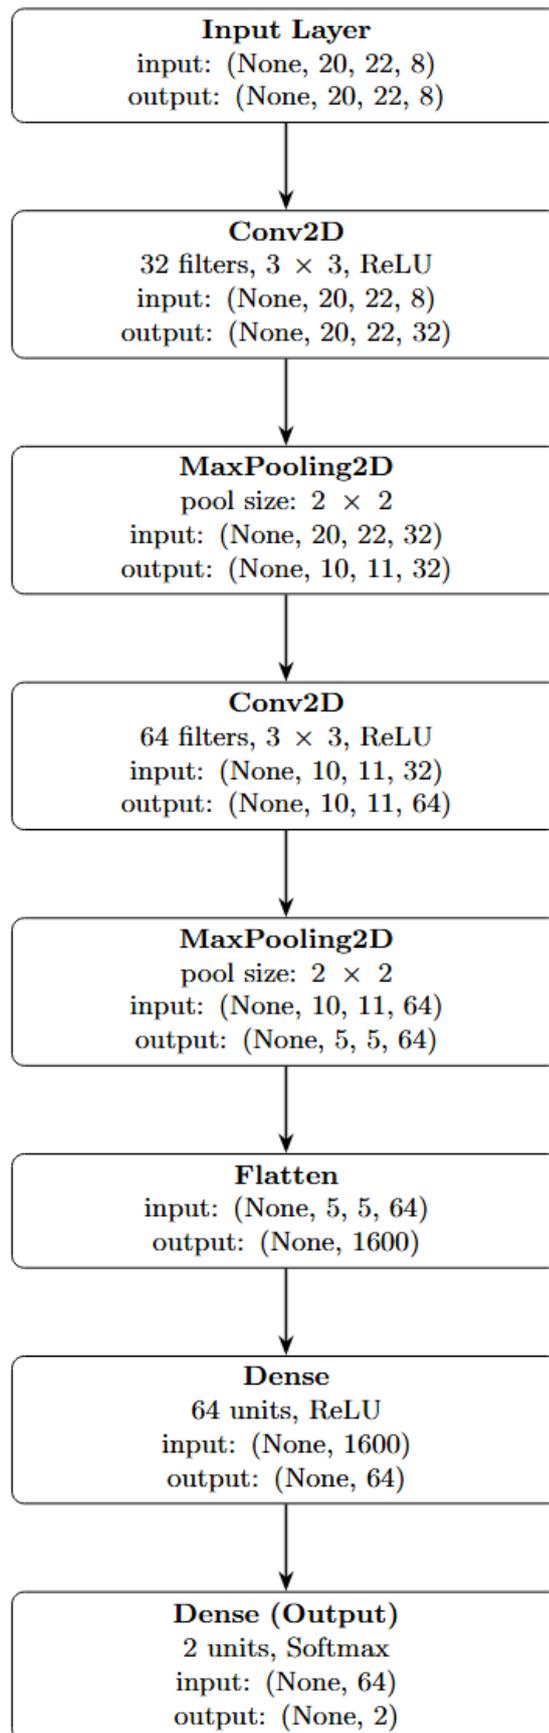


Gambar 3.3: Input CNN

Ukuran input CNN yang telah ditentukan memungkinkan model untuk memproses data dari setiap potongan sinyal EEG dan channel untuk mengenali pola yang penting dalam frekuensi dan waktu. Dengan input ini, model bisa melihat hubungan antara frekuensi, waktu, dan channel EEG secara bersamaan. Ini membantu model untuk lebih mudah mengenali perbedaan pola dalam sinyal EEG, seperti yang terlihat pada orang yang sehat dan yang mengalami depresi. Format input yang jelas dan terstruktur ini mempermudah model dalam mengekstraksi informasi penting yang akan digunakan untuk menentukan kondisi otak berdasarkan sinyal EEG.

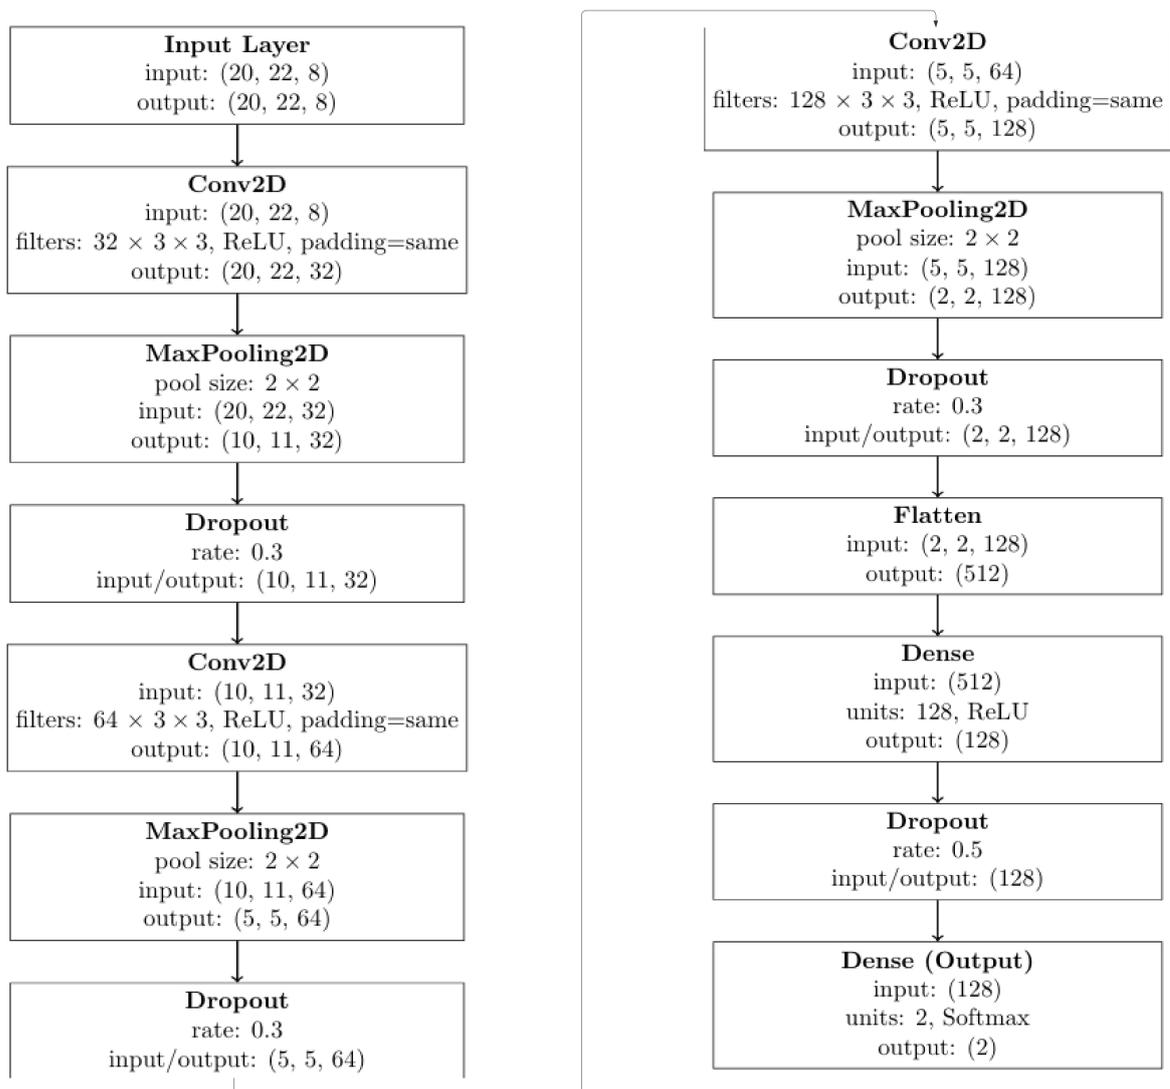
3.7 Pembuatan Model

Berikut ini adalah diagram arsitektur CNN yang digunakan untuk klasifikasi kondisi EEG. Model ini dirancang dengan dua blok konvolusi 2D yang masing-masing diikuti lapisan pooling, sebuah lapisan Flatten untuk meratakan keluaran konvolusi menjadi vektor, dan dua lapisan Dense untuk melakukan klasifikasi. Blok pertama menggunakan 32 filter berukuran 3×3 , sedangkan blok kedua menggunakan 64 filter 3×3 ; setiap blok diakhiri dengan pooling 2×2 untuk mereduksi dimensi spasial. Setelah itu, vektor hasil Flatten diproses oleh lapisan tersembunyi dengan 64 neuron, dan lapisan output dengan 2 neuron serta aktivasi softmax menghasilkan probabilitas kelas sehat atau depresi. Di bawah ini Gambar 3.4 dapat melihat skema lengkap alur data melalui setiap lapisan dalam model CNN ini.



Gambar 3.4: Arsitektur CNN Model 1

Pada tahap pembuatan model, pertama-tama kita menyiapkan data PSD_{\log} yang sebenarnya adalah sekumpulan “gambar” berukuran 20 baris frekuensi \times 22 kolom waktu \times 8 channel. Setiap nilai pada gambar ini dinormalisasi sehingga memiliki rata-rata nol dan variansi satu—langkah ini penting agar jaringan tidak terbebani oleh skala angka yang terlalu besar atau terlalu kecil. Selanjutnya, data dibagi menjadi tiga kelompok: 70% untuk melatih model (training), 10% untuk memantau performa model di tengah pelatihan (validasi), dan 20% untuk menguji kemampuan akhir model (testing). Label asli 0 dan 1 diubah menjadi format [1, 0] atau [0, 1] supaya sesuai dengan lapisan terakhir yang mengeluarkan dua angka probabilitas dan memudahkan perhitungan loss. Arsitektur CNN yang dipakai cukup sederhana: pertama dua blok konvolusi 2D dengan filter berukuran 3×3 blok pertama 32 filter, kemudian blok kedua 64 filter yang masing-masing diikuti lapisan pooling 2×2 untuk mereduksi dimensi dan mencegah overfitting. Keluaran blok terakhir di-*flatten* menjadi vektor satu dimensi, lalu masuk ke lapisan *Dense* dengan 64 neuron untuk mempelajari kombinasi fitur, sebelum akhirnya lapisan *Dense* kedua dengan 2 neuron dan aktivasi *softmax* memberikan probabilitas kelas sehat atau depresi. Model ini dikompilasi dengan optimizer *Adam* karena cepat menyesuaikan laju pembelajaran dan fungsi loss *categorical_crossentropy*. Pelatihan dijalankan selama 30 epoch dengan batch size 16, sambil memantau akurasi pada data validasi untuk mencegah overfitting. Setelah selesai, bobot dan konfigurasi model disimpan dalam format `.keras` dan `.h5` sehingga bisa langsung dipakai untuk memprediksi data EEG baru.



Gambar 3.5: Arsitektur CNN Model 2

Model kedua dalam penelitian ini dimulai dengan lapisan Conv2D pertama yang memiliki 32 filter dengan ukuran kernel 3x3, diikuti oleh MaxPooling2D dengan ukuran pool 2x2 dan Dropout 0.3 untuk mengurangi overfitting. Selanjutnya, terdapat lapisan Conv2D kedua dengan 64 filter dan ukuran kernel 3x3, diikuti oleh MaxPooling2D 2x2 dan Dropout 0.3 untuk regularisasi lebih lanjut. Model kemudian dilanjutkan dengan lapisan Conv2D ketiga yang memiliki 128 filter dan ukuran kernel 3x3, diikuti lagi dengan MaxPooling2D dan Dropout 0.3. Setelah serangkaian lapisan konvolusional, model diratakan menggunakan lapisan Flatten. Selanjutnya, terdapat lapisan Dense dengan 128 unit yang diikuti oleh Dropout 0.5 untuk mencegah overfitting lebih lanjut. Model diakhiri dengan lapisan Dense terakhir yang memiliki 2 unit, masing-masing mewakili dua kelas (Sehat dan Depresi), dengan aktivasi Softmax untuk menghasilkan probabilitas prediksi untuk masing-masing kelas.

Diharapkan dengan kedua model ini adalah untuk mencapai akurasi yang tinggi dalam mengklasifikasikan sinyal EEG berdasarkan kondisi mental seperti sehat atau depresi. Model pertama yang lebih sederhana diharapkan dapat memberikan hasil yang efisien dan cukup baik dalam mengenali pola-pola dasar dalam sinyal EEG dengan sedikit kemungkinan overfitting,

karena struktur arsitektur yang tidak terlalu kompleks. Model kedua, dengan lapisan konvolusi yang lebih dalam dan penggunaan dropout lebih tinggi, bertujuan untuk meningkatkan kemampuan model dalam menangkap fitur yang lebih kompleks dan mendalam, terutama dalam menangani data yang lebih bervariasi dan kompleks. Dengan penambahan lebih banyak lapisan dan regularisasi, model ini diharapkan dapat meningkatkan generalisasi dan mengurangi overfitting, yang pada gilirannya meningkatkan kemampuan prediksi pada data yang belum pernah dilihat sebelumnya. Kedua model ini diharapkan mampu memberikan hasil yang lebih akurat dan dapat diandalkan dalam mendiagnosis kondisi depresi berdasarkan analisis sinyal EEG.

BAB IV

PENGUJIAN DAN ANALISIS

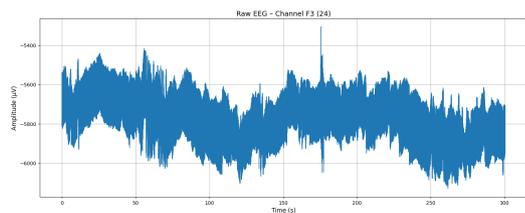
Pada bab ini akan dipaparkan rangkaian pengujian dan analisis hasil penelitian dari desain dan implementasi yang telah dijelaskan sebelumnya.

4.1 Deskripsi Data EEG

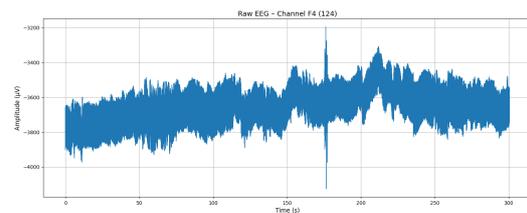
Dataset terdiri dari sinyal EEG resting state depresi dan sehat dengan 128 channel yang direkam pada sampling rate 250 Hz dan disimpan dalam format .mat. Dari keseluruhan channel, delapan channel dipilih untuk analisis, yakni F3, F4, C3, C4, P3, P4, O1, dan O2. Berikut sinyal mentah untuk masing-masing channel untuk kondisi sehat pada Gambar 4.1 dan Gambar 4.2.

Sinyal EEG sehat Gambar 4.1 yang tercatat yaitu C4, C3, F4, dan F3, menunjukkan fluktuasi amplitudo yang cukup besar, yang seringkali menjadi ciri khas data EEG mentah. Channel C4 dan C3 memperlihatkan pola kenaikan amplitudo dengan puncak tajam yang mengindikasikan kemungkinan adanya noise atau artefak. Di sisi lain, channel F4 menunjukkan pola fluktuasi yang lebih tidak teratur, dengan perubahan amplitudo yang signifikan dan puncak tajam yang lebih jelas, sementara channel F3 juga menunjukkan fluktuasi besar yang kemungkinan dipengaruhi oleh gangguan eksternal. Semua saluran ini menunjukkan pola yang tidak halus, yang mengindikasikan adanya artefak meskipun tetap mencerminkan fluktuasi alami yang umumnya terlihat pada orang sehat.

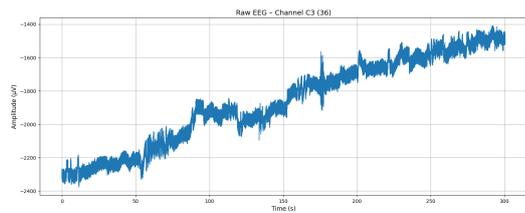
Pada Gambar 4.1 di saluran O2 dan O1, fluktuasi amplitudo menunjukkan perubahan yang lebih halus yang berhubungan dengan tingkat aktivitas otak yang dipengaruhi oleh kondisi mental atau tingkat relaksasi. Peningkatan amplitudo secara bertahap pada saluran O1 dapat menunjukkan transisi menuju keadaan otak yang lebih aktif, sementara saluran P4 menunjukkan variasi amplitudo yang lebih besar, yang mengindikasikan respons otak terhadap stimulus eksternal atau aktivitas kognitif yang lebih intens. Saluran P3, di sisi lain, menunjukkan penurunan amplitudo secara bertahap, yang seringkali terjadi saat otak memasuki keadaan relaksasi atau berkurangnya aktivitas mental. Secara keseluruhan, pola sinyal EEG ini mencerminkan variasi alami dalam aktivitas otak yang sehat dan respons otak terhadap berbagai kondisi atau rangsangan.



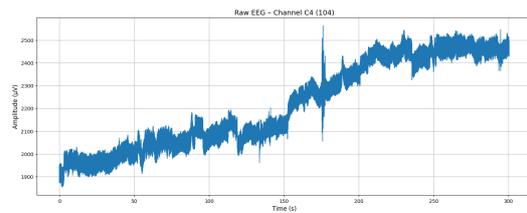
(a) F3



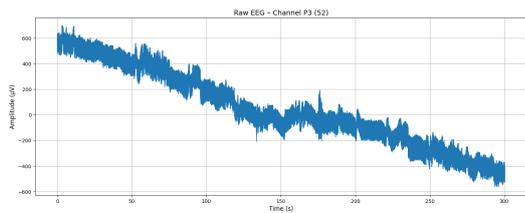
(b) F4



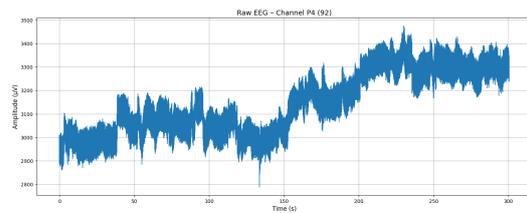
(c) C3



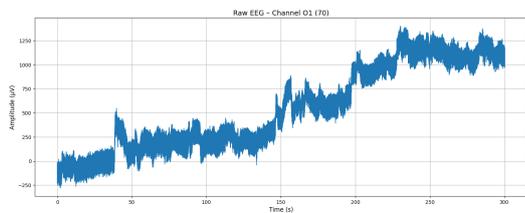
(d) C4



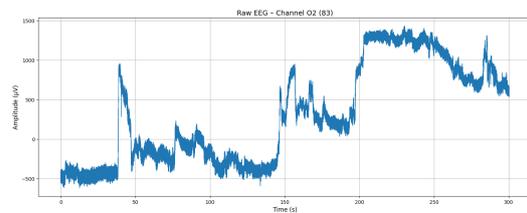
(e) P3



(f) P4



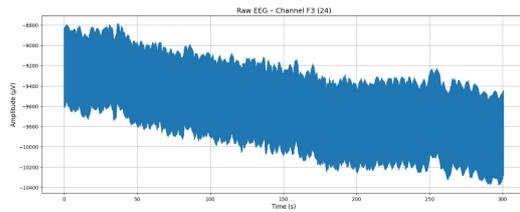
(g) O1



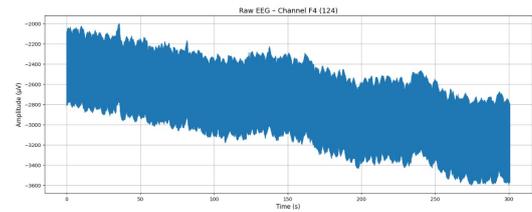
(h) O2

Gambar 4.1: Plot sinyal EEG mentah untuk channel F3, F4, C3, C4, P3, P4, O1, dan O2 pada kondisi sehat.

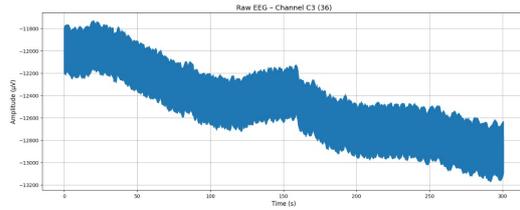
Pada Gambar 4.2 sinyal EEG mentah depresi ini menunjukkan fluktuasi yang khas, mencerminkan aktivitas listrik di otak. Misalnya, pada saluran O2 dan O1, terlihat adanya kenaikan amplitudo yang lambat dengan beberapa puncak tajam, yang mungkin menunjukkan adanya gangguan atau artefak eksternal. Saluran P4 menunjukkan penurunan amplitudo secara bertahap sepanjang rangkaian waktu, yang mengindikasikan penurunan aktivitas otak. Sebaliknya, saluran P3 dan F3 menunjukkan variasi amplitudo yang lebih besar, yang bisa jadi berhubungan dengan pergeseran kognitif atau emosional. Data saluran ini terlihat agak noise, yang mungkin disebabkan oleh faktor lingkungan, interferensi sensor, atau artefak fisiologis.



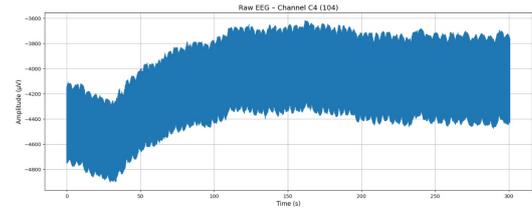
(a) F3



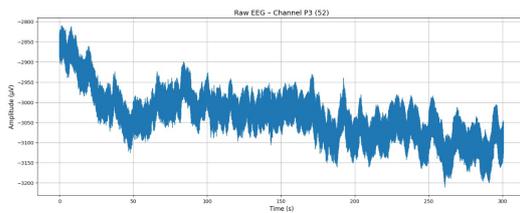
(b) F4



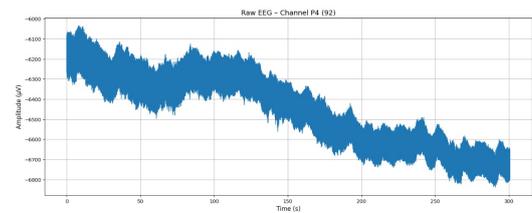
(c) C3



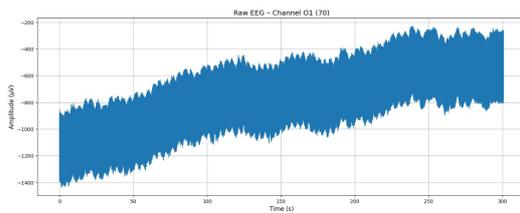
(d) C4



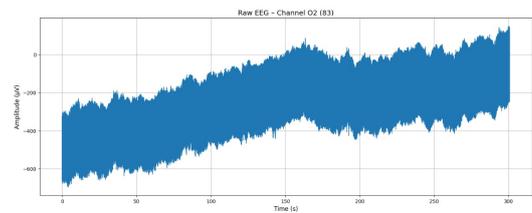
(e) P3



(f) P4



(g) O1



(h) O2

Gambar 4.2: Plot sinyal EEG mentah untuk channel F3, F4, C3, C4, P3, P4, O1, dan O2 pada kondisi depresi.

Saluran F4 dan C4 menunjukkan pola yang serupa, dengan amplitudo yang meningkat secara konsisten seiring waktu, meskipun terdapat beberapa ketidakteraturan. Pola kenaikan ini mungkin mengindikasikan perubahan kondisi otak, yang berhubungan dengan transisi antar fase aktivitas, seperti relaksasi atau upaya mental. Variasi amplitudo yang terlihat pada saluran-saluran ini merupakan hal yang umum pada sinyal EEG mentah, di mana kebisingan sering muncul, terutama jika subjek tidak berada dalam kondisi sepenuhnya rileks. Secara keseluruhan, meskipun beberapa saluran menunjukkan tren peningkatan atau penurunan aktivitas otak yang diharapkan, fluktuasi amplitudo yang signifikan di semua saluran ini menunjukkan

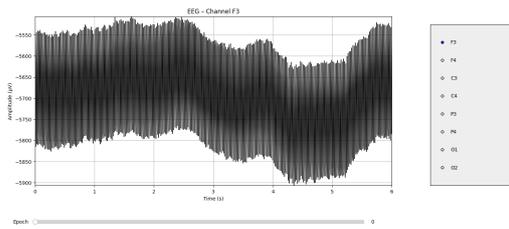
bahwa data EEG mentah ini perlu melalui pra-pemrosesan, seperti pemfilteran dan penghapusan artefak, sebelum analisis lebih lanjut dapat dilakukan.

4.2 Plot Time Segmenting

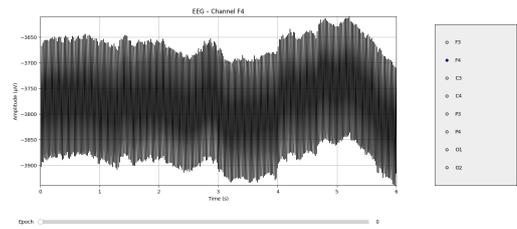
Setiap rekaman per subjek berdurasi sekitar 5 menit, kemudian dibagi menjadi segment sepanjang 6 detik dengan overlap 50% (3 detik). Hasil segmentasi menghasilkan antara 99–109 epoch untuk kelas depresi dan 99–110 epoch untuk kelas sehat. Berikut hasil time segmenting pada Gambar 4.3 dan Gambar 4.4

Plot segmenting sinyal EEG sehat yang ditampilkan pada Gambar 4.3 menunjukkan variasi amplitudo pada berbagai saluran otak, yang dapat mencerminkan aktivitas otak yang terjadi selama periode pengukuran. Saluran P3 dan F4 menunjukkan fluktuasi amplitudo yang lebih besar, menandakan aktivitas otak yang lebih intens, mungkin karena respons terhadap rangsangan atau pemrosesan kognitif yang tinggi. Saluran-saluran ini sering kali terkait dengan proses perhatian dan pengambilan keputusan. Di sisi lain, saluran O1 dan O2 menunjukkan pola yang lebih stabil, yang bisa mencerminkan aktivitas yang lebih tenang, seperti pemrosesan visual atau relaksasi.

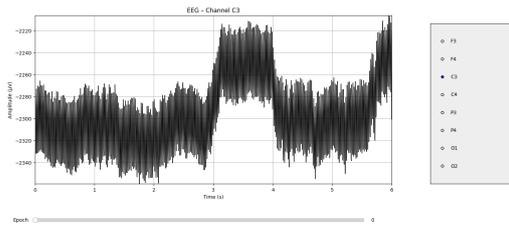
Perbedaan amplitudo di antara saluran-saluran ini mengindikasikan bahwa masing-masing bagian otak memproses jenis informasi yang berbeda. Misalnya, saluran P4 dan C4 menunjukkan perubahan amplitudo yang lebih besar, yang bisa terkait dengan pemrosesan sensorimotor, sementara saluran O1 dan O2 lebih stabil, mencerminkan aktivitas visual. Fluktuasi ini memberikan wawasan tentang kondisi mental dan tingkat kewaspadaan subjek, serta bagaimana otak merespons berbagai jenis rangsangan atau stimulus.



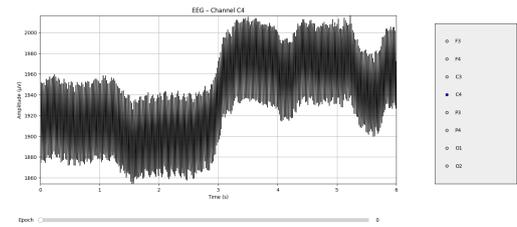
(a) Epoch F3



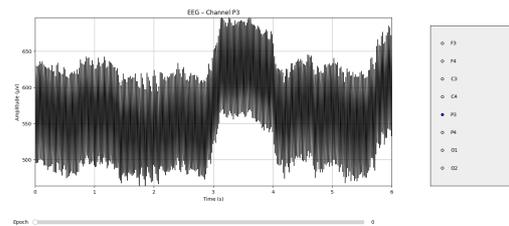
(b) Epoch F4



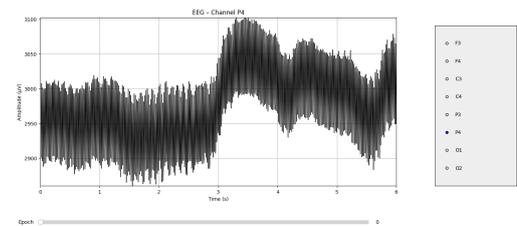
(c) Epoch C3



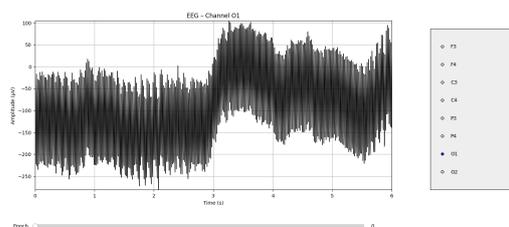
(d) Epoch C4



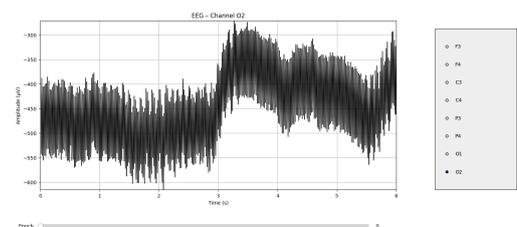
(e) Epoch P3



(f) Epoch P4



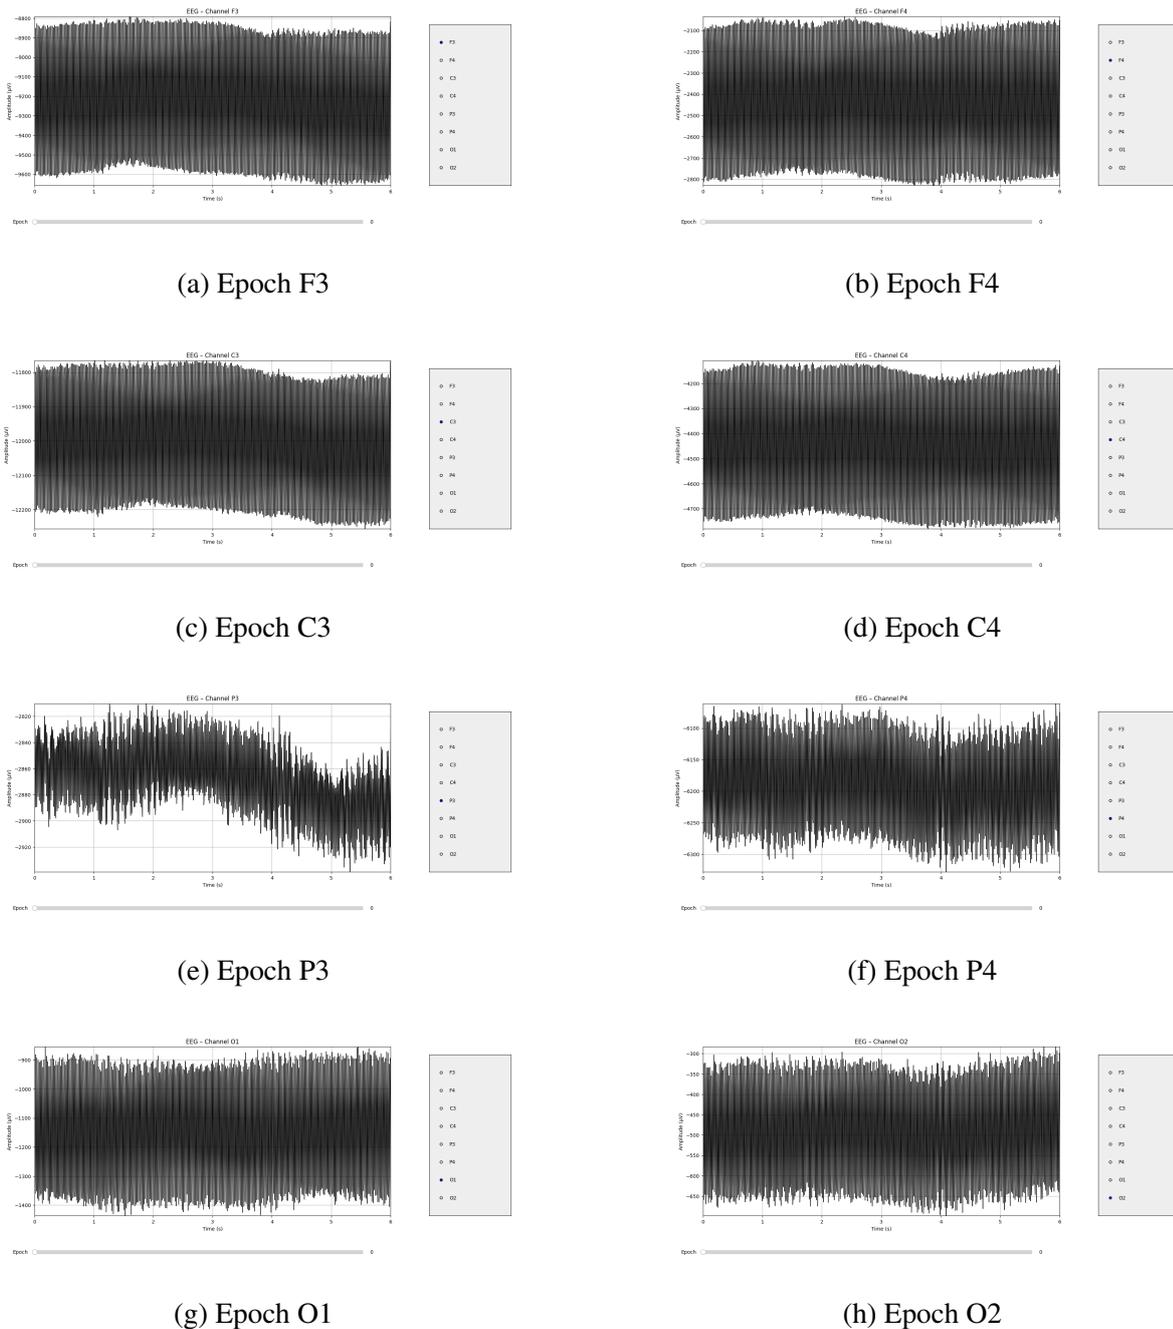
(g) Epoch O1



(h) Epoch O2

Gambar 4.3: Plot epoch pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi sehat.

Dari Gambar 4.4 plot time segmenting pada sinyal EEG depresi di kedelapan saluran (O2, O1, P4, P3, C4, C3, F3, dan F4), terlihat bahwa semua saluran menunjukkan fluktuasi amplitudo yang cukup besar. Saluran O1 dan O2 menunjukkan variasi amplitudo yang sangat besar, dengan O1 menunjukkan fluktuasi yang lebih tinggi dibandingkan O2, yang bisa menunjukkan adanya aktivitas otak yang lebih intens atau kemungkinan adanya gangguan atau noise pada sinyal. Saluran P4 dan P3 menunjukkan fluktuasi besar pada P4, namun P3 terlihat sedikit lebih stabil, meskipun masih terdapat fluktuasi amplitudo yang signifikan.



Gambar 4.4: Plot epoch pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi depresi.

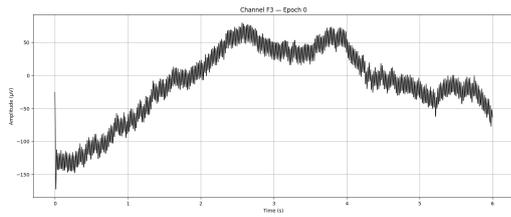
Pada Gambar 4.4 saluran C4 dan C3, amplitudo juga cukup tinggi dengan variasi yang sangat besar, menandakan adanya aktivitas otak yang cukup aktif. Namun, saluran C3 menunjukkan pola yang lebih stabil dan konsisten dengan fluktuasi amplitudo yang lebih teratur. Sementara itu, saluran F3 dan F4 menunjukkan pola yang lebih stabil dengan fluktuasi amplitudo negatif dan positif yang signifikan, namun tidak seaktif saluran lainnya. Secara keseluruhan, meskipun ada fluktuasi alami dalam sinyal EEG, beberapa saluran menunjukkan adanya gangguan atau noise, yang perlu diperbaiki agar analisis lebih akurat.

4.3 Filterisasi Sinyal

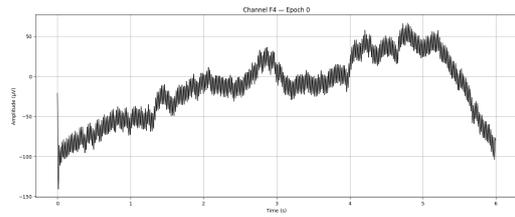
Untuk menghilangkan komponen frekuensi rendah dan artefak high-frequency noise, sinyal setiap epoch menjalani proses band-pass filtering pada rentang 0,1–40 Hz menggunakan filter Butterworth orde empat dengan zero-phase filtering. Hasilnya dapat dilihat pada Gambar 4.5 dan Gambar 4.6

Pada Gambar 4.5 sinyal EEG sehat yang telah diproses menggunakan filter bandpass dengan rentang frekuensi 0,1 hingga 40 Hz menunjukkan pola aktivitas otak yang khas. Filter ini efektif menghilangkan noise atau artefak yang berada di luar rentang frekuensi gelombang otak yang biasa. Secara umum, sinyal pada semua channel menunjukkan fluktuasi amplitudo yang bervariasi sepanjang waktu, yang mencerminkan perubahan aktivitas otak. Fluktuasi amplitudo ini menunjukkan perubahan dalam tingkat aktivitas otak, yang dapat dipengaruhi oleh kondisi mental atau perubahan keadaan fisik.

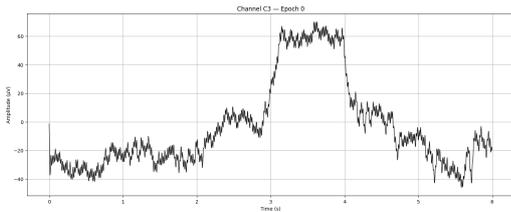
Pada beberapa channel di Gambar 4.5, seperti channel C3 dan C4, terlihat adanya perubahan amplitudo yang signifikan. Hal ini dapat mengindikasikan adanya perubahan dalam aktivitas otak pada area tertentu, yang mungkin terkait dengan jenis aktivitas otak yang lebih tinggi atau lebih rendah. Sementara itu, saluran O1 dan O2 menunjukkan tren yang lebih halus, yang bisa menunjukkan pola aktivitas otak yang lebih stabil atau terkait dengan fungsi visual dan penglihatan. Namun, pada beberapa titik awal sinyal, terlihat adanya lonjakan tiba-tiba yang bisa jadi merupakan artefak transien, meskipun filter bandpass sudah mengurangi pengaruhnya dengan cukup baik. Secara keseluruhan, sinyal yang telah difilter ini tampak siap untuk dilakukan analisis lebih lanjut,



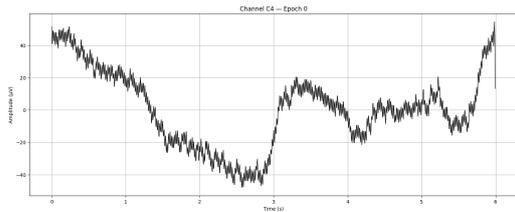
(a) bp_F3



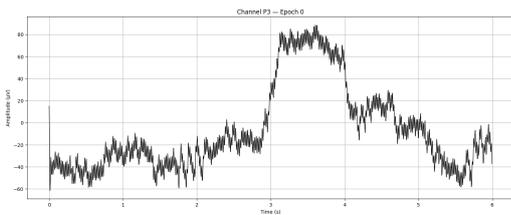
(b) bp_F4



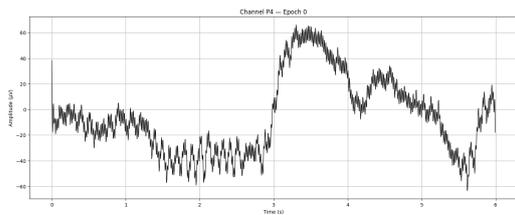
(c) bp_C3



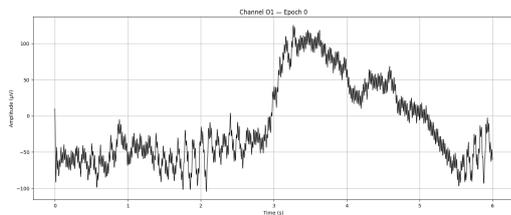
(d) bp_C4



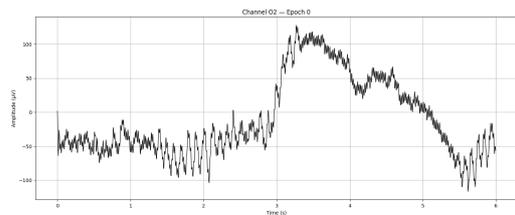
(e) bp_P3



(f) bp_P4



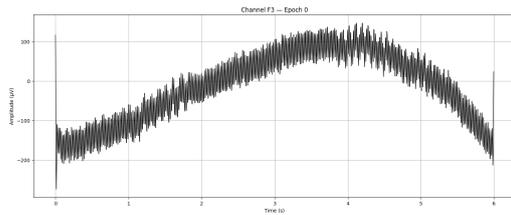
(g) bp_O1



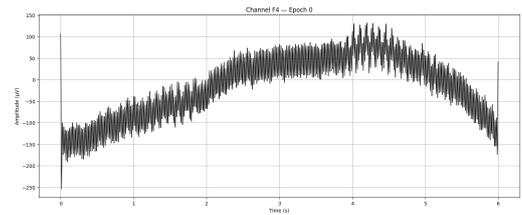
(h) bp_O2

Gambar 4.5: Plot sinyal EEG setelah bandpass pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi sehat.

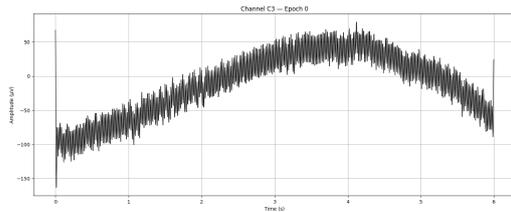
Gambar-gambar sinyal EEG dari kedelapan saluran menunjukkan pola fluktuasi yang berbeda-beda, menggambarkan aktivitas otak di berbagai area. Channel O2 dan O1 menunjukkan fluktuasi besar dengan puncak tajam, yang mengindikasikan aktivitas visual yang signifikan, kemungkinan terkait dengan rangsangan visual atau pergerakan mata. Sementara itu, Channel P4 dan P3 menunjukkan pola yang lebih stabil, dengan P4 lebih berfokus pada pemrosesan sensorik dan P3 menunjukkan peningkatan aktivitas yang berkaitan dengan perhatian atau pemrosesan informasi sensorik. Di sisi lain, Channel C4 dan C3 menunjukkan fluktuasi tajam yang bisa jadi mengindikasikan adanya gangguan atau artefak dalam sinyal.



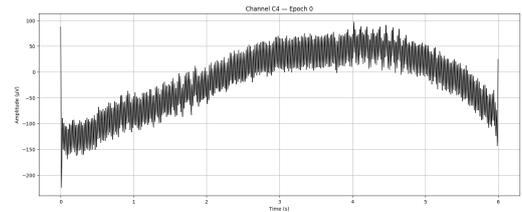
(a) bp_F3



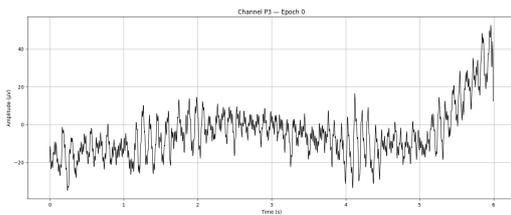
(b) bp_F4



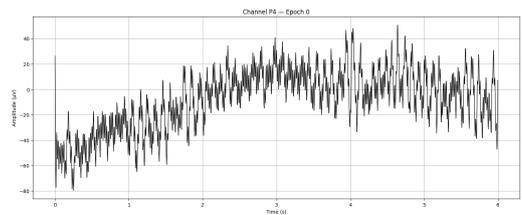
(c) bp_C3



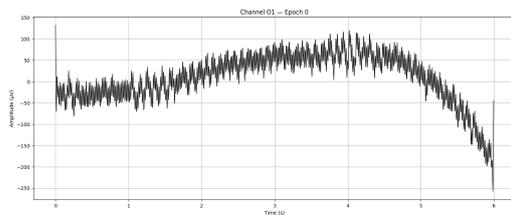
(d) bp_C4



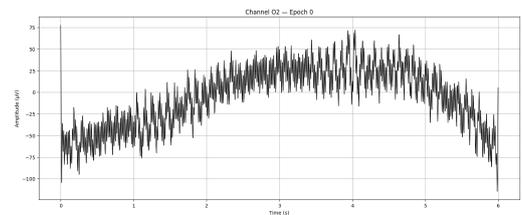
(e) bp_P3



(f) bp_P4



(g) bp_O1



(h) bp_O2

Gambar 4.6: Plot sinyal EEG setelah bandpass pada channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi depresi.

Setelah proses filtering, sinyal EEG pada kedua kondisi, sehat dan depresi, berfluktuasi di sekitar nol tanpa adanya pergeseran baseline. Pada kelompok sehat, amplitudo fluktuasi relatif besar dengan sering munculnya puncak tajam yang mencerminkan fluktuasi frekuensi menengah hingga tinggi, menunjukkan variasi aktivitas otak yang signifikan dan respons dinamis terhadap rangsangan atau perubahan kondisi mental. Sebaliknya, pada kelompok depresi, amplitudo fluktuasi lebih kecil dengan transien yang lebih halus, mencerminkan kestabilan otak yang lebih besar dan kurangnya variasi tajam dalam aktivitas neural. Dengan demikian, meskipun artefak telah dihilangkan, sinyal EEG pada kelompok sehat mempertahankan variasi amplitudo

yang lebih besar, sementara sinyal EEG pada kelompok depresi menunjukkan kestabilan yang lebih besar.

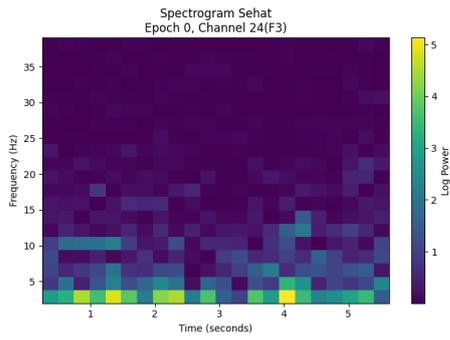
Secara keseluruhan, filter bandpass berhasil mengurangi noise pada sinyal EEG dan memberikan gambaran yang lebih jelas tentang aktivitas otak pada setiap saluran. Fluktuasi yang terlihat pada setiap saluran memberikan wawasan yang berbeda tergantung pada area otak yang terlibat, baik itu pengolahan visual, sensorik, motorik, atau kognitif, yang memungkinkan analisis lebih lanjut terkait respons otak terhadap rangsangan atau gangguan eksternal, serta membantu membedakan kondisi sehat dan depresi berdasarkan pola aktivitas otak yang tercatat.

4.4 Hasil Power Spectral Density

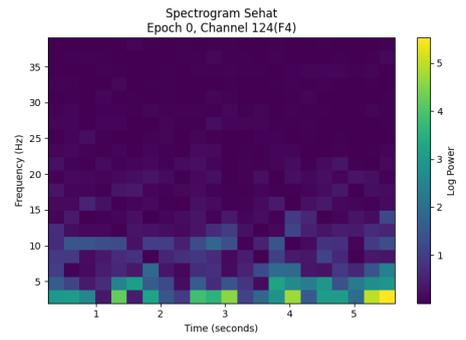
Setelah filtering, setiap epoch diekstraksi spektrumnya menggunakan Short-Time Fourier Transform (STFT) dengan parameter $n_{\text{perseg}}=128$ dan $n_{\text{overlap}}=64$, kemudian dilakukan log-transformation (\log_{10}) untuk menormalkan rentang nilai. Pada Gambar 4.7 dan Gambar 4.8 untuk kondisi depresi.

Pada Gambar 4.7, setiap channel menunjukkan pola daya yang dominan pada frekuensi rendah (5-10 Hz), yang umumnya terkait dengan keadaan relaksasi atau otak yang tidak aktif secara intensif. Channel F3 dan F4 menunjukkan sedikit peningkatan daya pada frekuensi rendah sekitar 3-4 detik, yang mengindikasikan kemungkinan peningkatan aktivitas otak dalam rentang waktu tersebut, namun tidak ada lonjakan besar yang mencolok. Channel C3 dan C4 memiliki pola yang serupa, dengan daya terdistribusi secara merata pada frekuensi rendah dan sedikit variasi pada interval waktu sekitar 2-3 detik, yang menandakan otak dalam kondisi yang relatif tenang atau fokus pada tugas kognitif ringan.

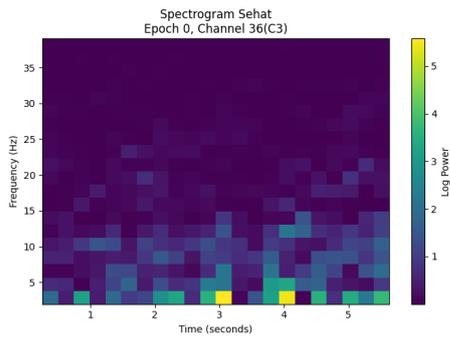
Channel P3 dan P4 memperlihatkan pola serupa dengan puncak daya pada frekuensi 5-10 Hz, dengan P3 menunjukkan sedikit variasi yang lebih jelas di sekitar 3 detik. Channel O1 dan O2, yang terletak pada area oksipital, menampilkan pola daya yang sangat seragam dengan dominasi daya rendah di seluruh rentang frekuensi, dengan sedikit peningkatan pada frekuensi rendah. Semua channel menunjukkan pola stabil yang terkait dengan keadaan relaksasi ringan atau ketenangan otak. Secara keseluruhan, sinyal EEG pada channel-channel ini menggambarkan otak yang tidak terlalu terstimulasi, umumnya dalam keadaan relaksasi atau istirahat, yang merupakan karakteristik umum dari kondisi otak sehat.



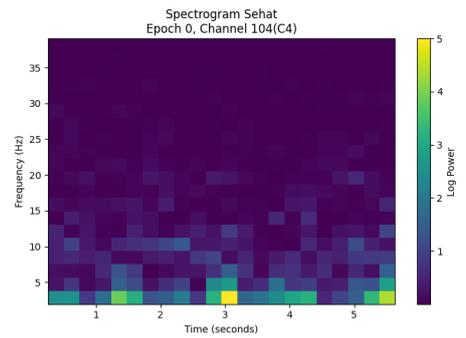
(a) Sehat F3



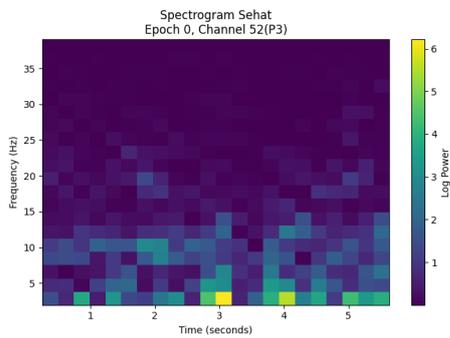
(b) Sehat F4



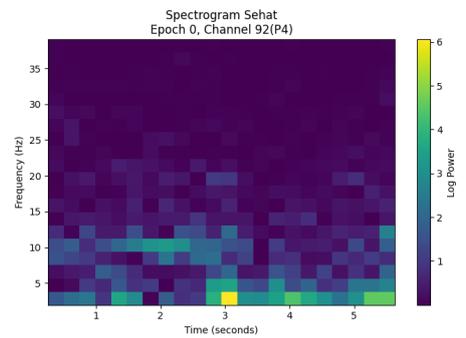
(c) Sehat C3



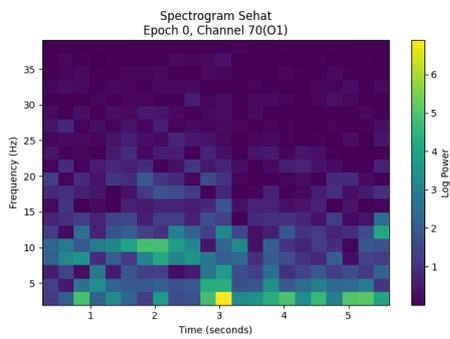
(d) Sehat C4



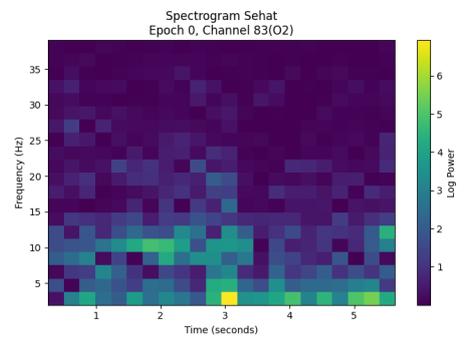
(e) Sehat P3



(f) Sehat P4



(g) Sehat O1

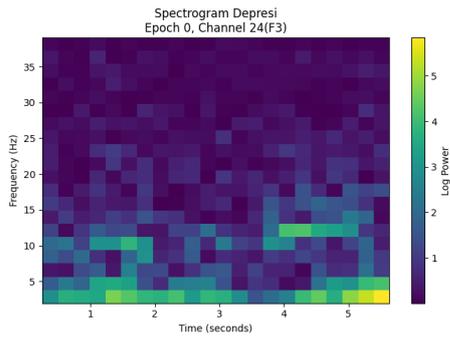


(h) Sehat O2

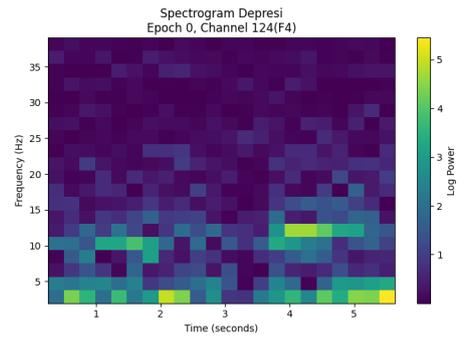
Gambar 4.7: Spektrogram PSD channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi sehat.

Spektrogram sinyal EEG pada delapan channel di Gambar 4.8 (F3, F4, C3, C4, P3, P4, O1, dan O2) untuk data depresi pada Epoch 0. Pada sebagian besar channel, terlihat dominasi frekuensi rendah (5–10 Hz), yang biasanya terkait dengan gelombang theta, mencerminkan keadaan otak yang cenderung lebih tenang atau relaksasi. Pada channel F3 dan F4, ada sedikit variasi pada frekuensi menengah (15–20 Hz), khususnya pada detik 2–3, yang mungkin mengindikasikan adanya perubahan dalam kondisi mental atau peningkatan aktivitas otak. Pola serupa juga terlihat pada channel C3 dan C4, meskipun fluktuasi pada frekuensi menengah lebih halus, dengan intensitas daya yang relatif rendah. Channel P3 dan P4 menunjukkan fluktuasi kecil pada frekuensi sekitar 10 Hz, namun aktivitas otak tetap stabil, menunjukkan kondisi otak yang tidak terlalu aktif.

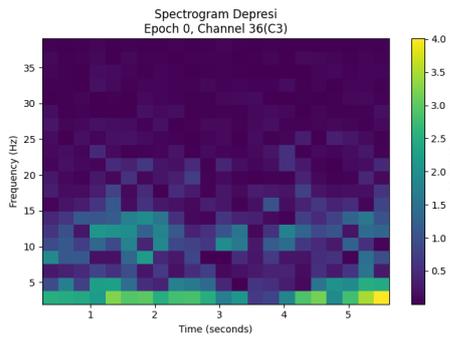
Pada channel O1 dan O2, pola dominasi frekuensi rendah tetap jelas, dengan sedikit lonjakan pada frekuensi menengah sekitar detik 3. Meskipun ada beberapa fluktuasi, aktivitas otak pada kedua channel ini tetap stabil, mencerminkan keadaan otak yang lebih stabil dan tidak banyak berubah. Secara keseluruhan, semua channel menunjukkan aktivitas dominan pada gelombang theta dengan sedikit variasi pada frekuensi menengah, mencerminkan perubahan yang lebih halus pada kondisi mental. Aktivitas otak dalam data depresi ini menunjukkan pola stabil dengan sedikit fluktuasi yang dapat menandakan perubahan dalam kondisi mental, namun tidak ada lonjakan signifikan yang menunjukkan ketidakstabilan mental yang berat.



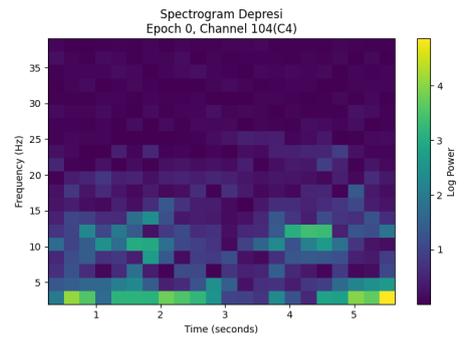
(a) Depresi F3



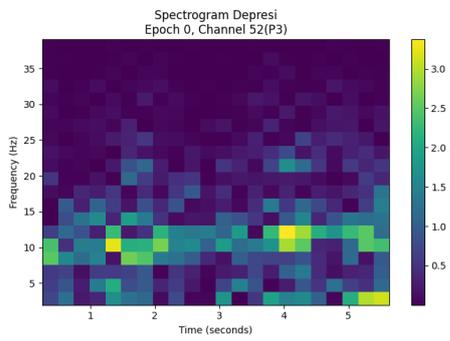
(b) Depresi F4



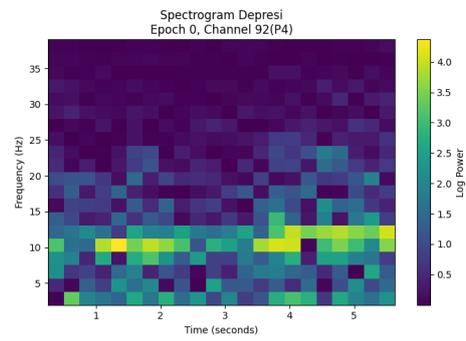
(c) Depresi C3



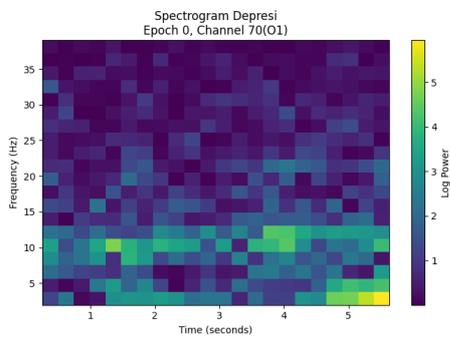
(d) Depresi C4



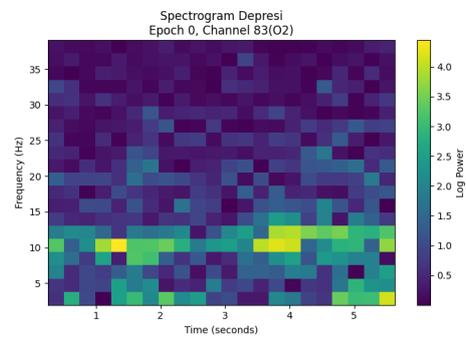
(e) Depresi P3



(f) Depresi P4



(g) Depresi O1



(h) Depresi O2

Gambar 4.8: Spektrogram PSD channel F3, F4, C3, C4, P3, P4, O1, dan O2 kondisi depresi.

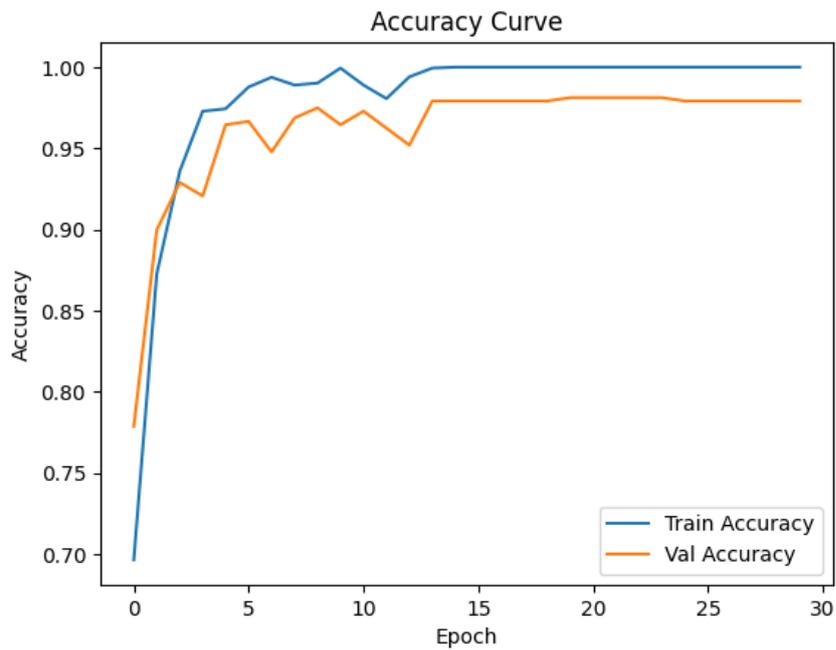
Pada sinyal sehat, energi frekuensi rendah (0–4 Hz) tampak sebagai loncatan singkat dan diselingi gelombang kecil pada rentang menengah (4–12 Hz), sementara energi di atas 12 Hz sangat rendah. Sebaliknya, pada sinyal depresi aktivitas frekuensi rendah terlihat lebih konsisten dan berkelanjutan tanpa banyak variasi di rentang menengah. Pola inilah loncatan singkat pada sehat dan aktivitas frekuensi rendah yang stabil pada depresi yang dipakai model CNN untuk membedakan kedua kondisi.

4.5 Eksperimen

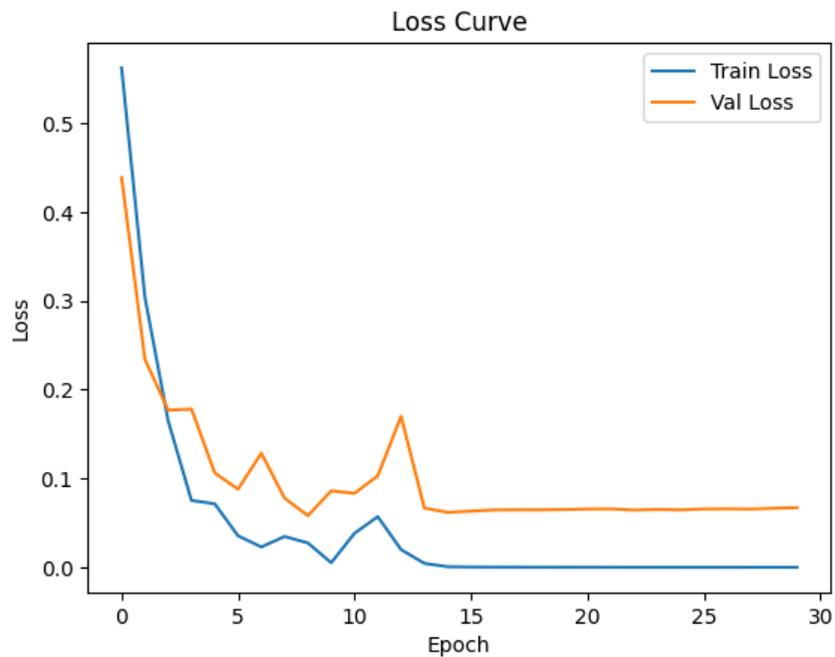
Eksperimen ini menggunakan dataset MODMA yang terdiri dari 53 rekaman EEG, yakni 29 subjek sehat dan 24 subjek depresi. Untuk menghindari ketidakseimbangan kelas, jumlah sampel sehat dikurangi menjadi 24 rekaman sehingga seimbang dengan kelas depresi. Selanjutnya data digabung dan dinormalisasi, lalu dibagi menjadi 70% training, 10% validation, dan 20% testing. Setelah pembagian data, tahap selanjutnya adalah pelatihan model menggunakan data training, dengan memantau performa pada data validation untuk menghindari overfitting. Proses pelatihan dilakukan dalam beberapa epoch, dan model dievaluasi pada akhir setiap epoch untuk memastikan akurasi yang optimal. Data testing yang tidak terlibat dalam proses pelatihan digunakan untuk menguji kemampuan model dalam melakukan klasifikasi pada data yang belum pernah dilihat sebelumnya. Dengan eksperimen ini, diharapkan dapat diperoleh model yang dapat secara efektif membedakan antara kondisi sehat dan depresi berdasarkan sinyal EEG, memberikan dasar yang kuat untuk aplikasi di bidang kesehatan mental.

4.5.1 Model 1

Model 1 ini dibangun dari dua blok Conv2D dengan kernel berukuran 3×3 , di mana blok pertama memiliki 32 filter dan blok kedua memiliki 64 filter. Setiap blok konvolusi diikuti oleh lapisan MaxPooling2D berukuran 2×2 untuk mereduksi dimensi spasial. Setelah itu, keluaran dari blok konvolusi diratakan menjadi vektor satu dimensi melalui lapisan Flatten. Vektor ini kemudian diproses oleh lapisan Dense yang berisi 64 neuron dengan aktivasi ReLU, sebelum akhirnya masuk ke lapisan output Dense berisi 2 neuron dengan aktivasi softmax untuk menghasilkan probabilitas dua kelas (Sehat vs. Depresi). Pelatihan model dilakukan selama 30 epoch dengan `batch_size=16`, menggunakan optimizer Adam dan fungsi loss `categorical_crossentropy`. Berikut hasil grafik dan confusion matrix dari model ini dapat dilihat dari Gambar 4.9 hingga Gambar 4.13.



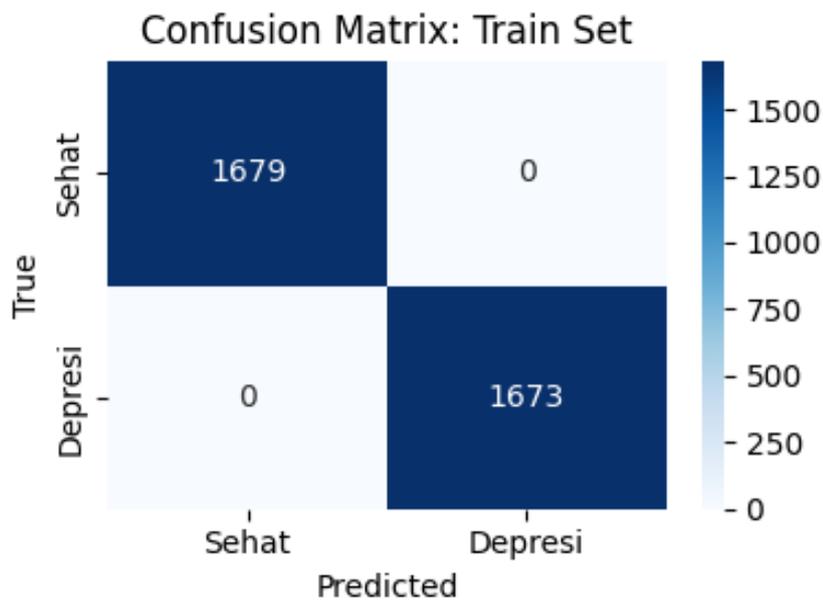
Gambar 4.9: Grafik Akurasi



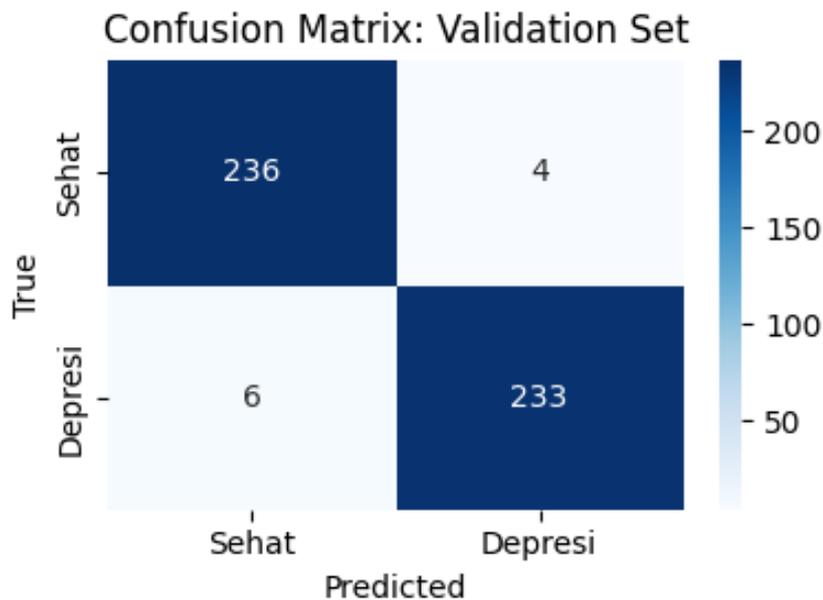
Gambar 4.10: Grafik Loss

Dari model ini menghasilkan grafik akurasi Gambar 4.9 dan grafik loss Gambar 4.10. Model ini menunjukkan hasil yang stabil pada train dan validation loss, dengan penurunan yang konsisten tanpa fluktuasi besar, yang mengindikasikan bahwa model dapat menggeneralisasi dengan baik. Meskipun ada sedikit perbedaan antara train accuracy dan validation accuracy, keduanya menunjukkan pola yang serupa, dengan peningkatan yang cepat di awal pelatihan

dan stabil pada level yang tinggi. Perbedaan kecil tersebut tidak signifikan, yang berarti model memberikan prediksi yang baik pada data latih maupun data validasi.



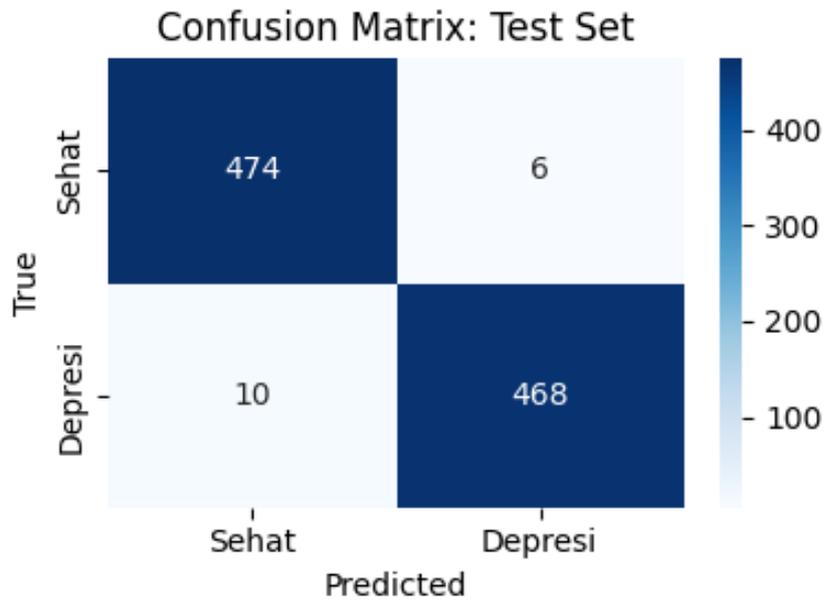
Gambar 4.11: Matrix Training Model 1



Gambar 4.12: Matrix Validation Model 1

Performa model dapat dilihat pada Gambar 4.11 (Train Set) dan Gambar 4.12 (Validation Set). Pada data pelatihan Gambar 4.11, model berhasil mengklasifikasikan semua sampel dengan benar, yakni 1 679 sampel sehat dan 1 673 sampel depresi, sehingga akurasi mencapai 100 %. Sementara itu, pada data validasi Gambar 4.12 terdapat 240 sampel sehat dan 239 sampel depresi; model mengklasifikasikan 236 sampel sehat dengan benar (4 salah) serta 233

sampel depresi dengan tepat (6 salah), sehingga akurasi keseluruhan pada set validasi mencapai sekitar 98 %. Hanya sedikit kesalahan klasifikasi yang terjadi di kedua kelas, menandakan bahwa model tidak sekadar “menghafal” data pelatihan, tetapi juga mampu mempertahankan kinerjanya saat dihadapkan pada data baru.



Gambar 4.13: Matrix Testing Model 1

Pada Confusion Matrix untuk test set (Gambar 4.13), model berhasil mengklasifikasikan 474 dari 480 sampel sehat dengan benar dan 468 dari 478 sampel depresi dengan tepat, sehingga terdapat 6 false positives (sampel sehat yang keliru dianggap depresi) dan 10 false negatives (sampel depresi yang keliru dianggap sehat). Kesalahan yang terjadi pada model kemungkinan besar disebabkan oleh dua faktor utama: overfitting dan keragaman data EEG. Overfitting terjadi karena model terlalu menyesuaikan diri dengan data pelatihan dan tidak dapat menggeneralisasi dengan baik pada data baru, seperti data validasi dan pengujian. Namun, keragaman data EEG juga berperan penting, karena variasi dalam data dapat membuat model kesulitan mengenali pola yang benar pada data yang berbeda. Jadi, baik overfitting maupun keragaman data dapat menyebabkan penurunan kinerja pada data yang belum dilihat sebelumnya..

Tabel 4.1: Hasil Klasifikasi Model CNN 1

Class	TP	TN	FP	FN
Sehat	474	468	10	6
Depresi	468	474	6	10

Tabel 4.2: Hasil Nilai Validasi Model 1

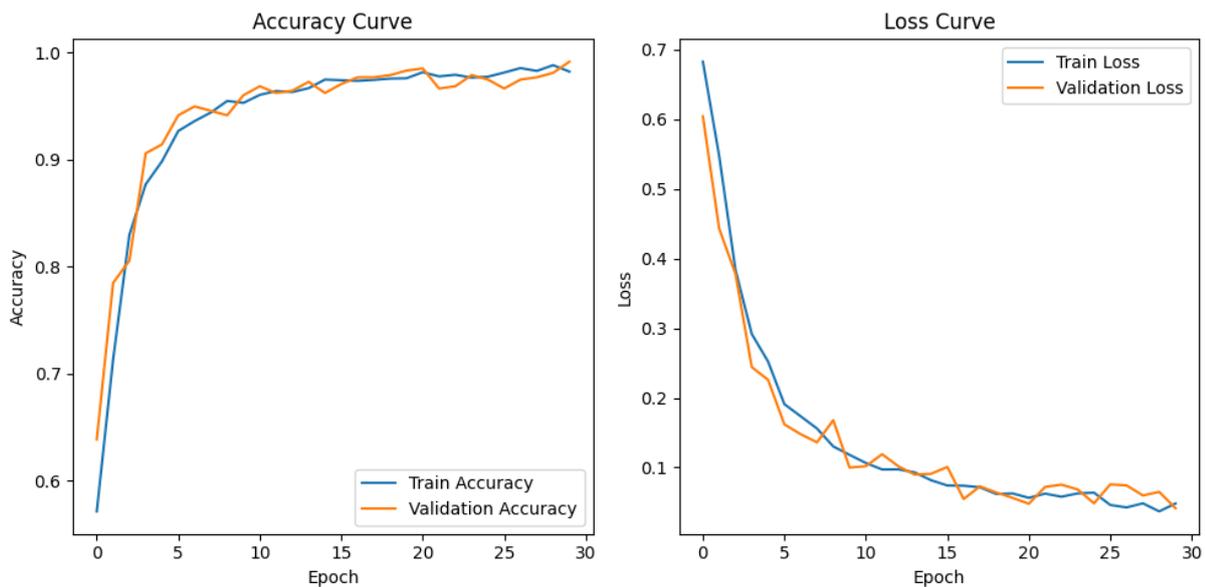
Class	Accuracy	Precision	Recall	F1-Score
Sehat	0.98	0.98	0.99	0.98
Depresi	0.98	0.99	0.98	0.98

Dari Tabel 4.1 terlihat bahwa pada test set model membuat total 16 kesalahan klasifikasi 6 sampel sehat yang tertukar sebagai depresi (false negatives) dan 10 sampel depresi yang tertukar sebagai sehat (false positives) dari keseluruhan 958 sampel. Ini berarti model berhasil mengklasifikasikan dengan benar 474 sampel sehat dan 468 sampel depresi.

Jika dilihat Tabel 4.2, akurasi per kelas sama-sama 98 %. Untuk kelas Sehat, precision sebesar 0.98 menunjukkan bahwa 98 % dari semua prediksi “Sehat” benar-benar sehat, dan recall 0.99 berarti model menangkap 99 % dari semua sampel sehat. Sebaliknya, untuk kelas Depresi precision 0.99 menunjukkan bahwa hampir semua prediksi “Depresi” benar, sedangkan recall 0.98 menandakan 98 % dari sampel depresi berhasil terdeteksi. Nilai F1-score keduanya sama-sama 0.98, yang mengindikasikan keseimbangan antara precision dan recall. Secara keseluruhan, kombinasi confusion matrix dan metrik precision–recall–F1 ini mengonfirmasi bahwa model tidak hanya sangat akurat, tetapi juga konsisten dalam mengenali kedua kelas.

4.5.2 Model 2

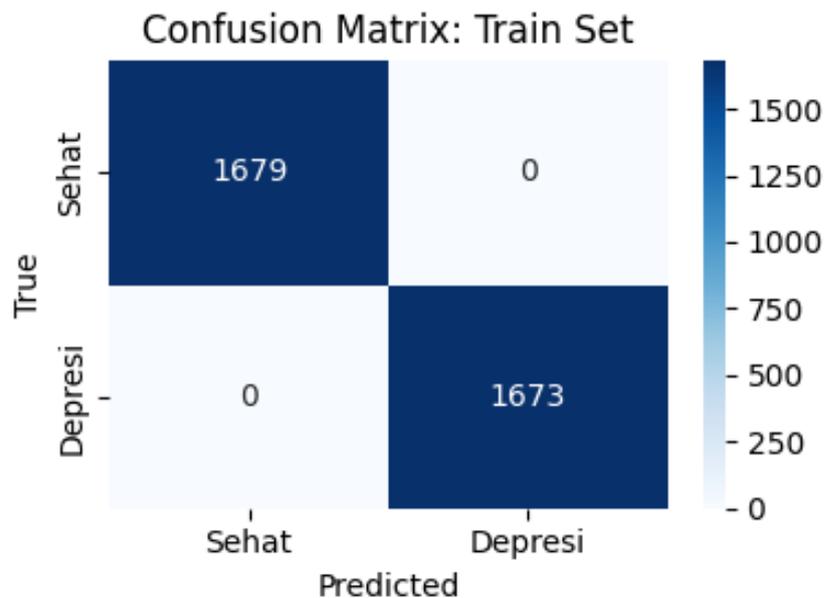
Model kedua ini menggunakan arsitektur CNN untuk klasifikasi data EEG, yang dimulai dengan lapisan Conv2D pertama yang memiliki 32 filter dan ukuran kernel (3, 3), diikuti oleh lapisan MaxPooling2D dan Dropout 0.3 untuk mengurangi overfitting. Model ini melanjutkan dengan lapisan Conv2D kedua dan ketiga yang masing-masing memiliki 64 dan 128 filter, diikuti oleh lapisan MaxPooling2D dan Dropout dengan rate 0.3. Setelah itu, data diluruskan menggunakan lapisan Flatten dan diteruskan ke lapisan Dense dengan 128 unit dan aktivasi ReLU, yang juga diikuti oleh Dropout 0.5 untuk regularisasi lebih lanjut. Akhirnya, model ini memiliki lapisan output Dense dengan dua unit dan aktivasi Softmax untuk klasifikasi dua kelas: Sehat dan Depresi. Model ini dilatih dengan optimizer Adam dan loss function categorical crossentropy.



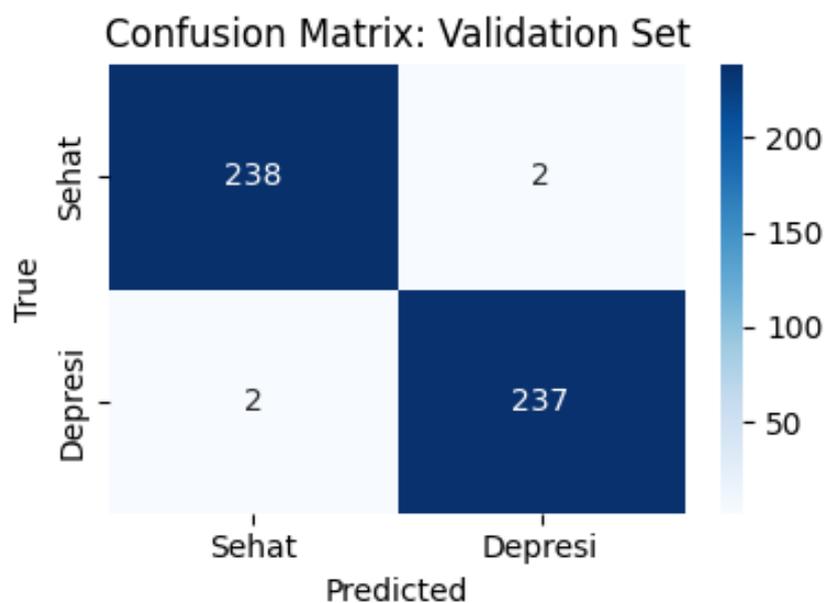
Gambar 4.14: Grafik Akurasi dan Loss Model

Grafik pada Gambar 4.14 tampilan menunjukkan bahwa model kedua berkinerja sangat baik dalam tugas klasifikasi data EEG. Akurasi pada data pelatihan meningkat dengan cepat

dan mencapai hampir 100%, sementara akurasi validasi juga menunjukkan hasil yang konsisten, meskipun sedikit lebih lambat. Ini menunjukkan bahwa model dapat belajar dengan baik dari data pelatihan dan juga mampu menggeneralisasi dengan baik ke data yang tidak terlihat sebelumnya. Di sisi lain, loss untuk data pelatihan dan validasi turun dengan cepat, mencapai nilai rendah di akhir pelatihan, yang menunjukkan bahwa model berhasil mengurangi kesalahan dengan efektif. Perbedaan antara loss pelatihan dan validasi yang kecil menunjukkan bahwa model tidak mengalami overfitting, sehingga hasilnya dapat diandalkan. Secara keseluruhan, model ini bekerja dengan baik.

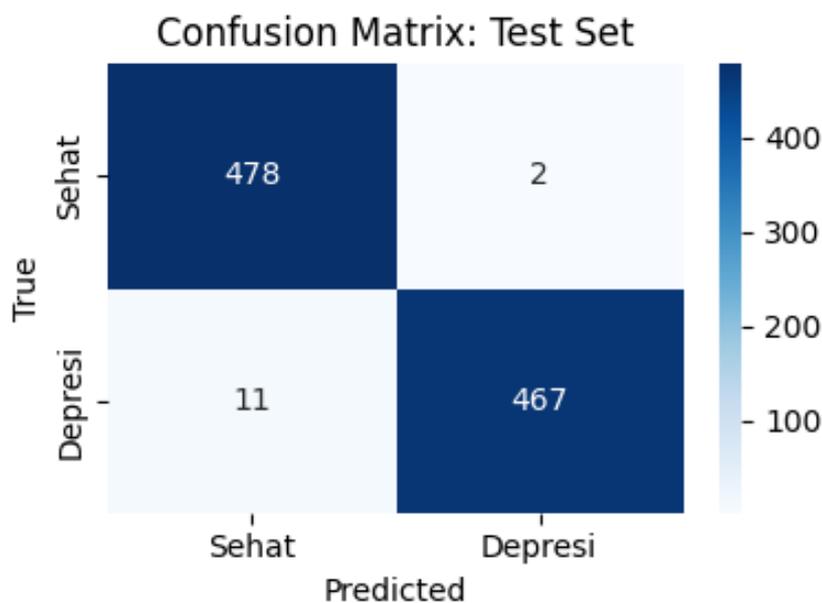


Gambar 4.15: Matrix Training Model 2



Gambar 4.16: Matrix Validation Model 2

Pada hasil train dan validation, model menunjukkan performa yang sangat baik. Di train set, model berhasil mengklasifikasikan hampir seluruh data dengan benar, tanpa adanya kesalahan prediksi, yang mencerminkan kemampuan model dalam mengenali pola dari data pelatihan dengan sangat baik. Di validation set, meskipun ada sedikit penurunan akurasi dengan 2 kesalahan untuk kelas "Sehat" dan 2 kesalahan untuk kelas "Depresi", model tetap mampu mempertahankan akurasi yang sangat tinggi, menunjukkan bahwa model dapat menggeneralisasi pola yang telah dipelajari pada data pelatihan ke data yang belum pernah dilihat sebelumnya. Secara keseluruhan, perbedaan kecil antara train dan validation menunjukkan bahwa model tidak mengalami overfitting, tetap stabil, dan memiliki kemampuan untuk mengenali pola secara efektif pada data yang baru.



Gambar 4.17: Matrix Testing Model 2

Pada confusion matrix test, model menunjukkan performa yang sangat baik dengan hanya 2 kesalahan pada kelas "Sehat" dan 11 kesalahan pada kelas "Depresi". Ini menunjukkan bahwa model hampir sepenuhnya mampu mengklasifikasikan data dengan benar pada test set. Namun, ada beberapa kesalahan, khususnya pada kelas "Depresi", di mana model salah mengklasifikasikan 11 data sebagai "Sehat". Kesalahan ini mungkin disebabkan oleh beberapa faktor, seperti ketidakseimbangan jumlah data antara kelas "Sehat" dan "Depresi" atau perbedaan pola yang lebih sulit dikenali oleh model pada kelas "Depresi". Meskipun demikian, tingkat kesalahan yang rendah ini menunjukkan bahwa model tetap sangat efektif dalam mengenali pola dari data yang tidak terlihat sebelumnya.

Pada tabel Tabel 4.3, model menunjukkan bahwa pada kelas "Sehat", terdapat 478 True Positives (TP), yang berarti model berhasil mengidentifikasi 478 data "Sehat" dengan benar. Namun, ada 11 data "Sehat" yang salah diklasifikasikan sebagai "Depresi" (False Negative, FN), dan 2 data "Sehat" yang salah diklasifikasikan sebagai "Depresi" (False Positive, FP). Begitu juga untuk kelas "Depresi", model berhasil mengidentifikasi 467 data "Depresi" dengan benar (TP), tetapi ada 11 data "Depresi" yang salah diklasifikasikan sebagai "Sehat" (FP) dan 2 data "Depresi" yang salah diklasifikasikan sebagai "Sehat" (FN). Secara keseluruhan, kesalahan

model sangat rendah, dengan hanya beberapa data yang salah dikategorikan, yang menunjukkan model bekerja dengan baik.

Tabel 4.3: Hasil Klasifikasi Model CNN 2

Class	TP	TN	FP	FN
Sehat	478	467	2	11
Depresi	467	478	11	2

Tabel 4.4: Hasil Nilai Validasi Model 2

Class	Accuracy	Precision	Recall	F1-Score
Sehat	0.99	0.98	1.00	0.99
Depresi	0.99	1.00	0.98	0.99

Pada Tabel 4.4, model memiliki akurasi tinggi 99% untuk kedua kelas, yang menunjukkan bahwa model mengklasifikasikan data dengan sangat baik. Untuk precision, kelas "Sehat" memiliki nilai 0.98, yang berarti 98% dari prediksi yang diberikan sebagai "Sehat" adalah benar. Sedangkan untuk kelas "Depresi", precision mencapai 1.00, yang berarti semua prediksi "Depresi" adalah benar. Nilai recall untuk kelas "Sehat" adalah 1.00, menunjukkan bahwa model berhasil mendeteksi semua data "Sehat" tanpa ada yang terlewat (false negatives). Sedangkan recall untuk kelas "Depresi" adalah 0.98, yang berarti 2% dari data "Depresi" terlewat atau tidak terdeteksi. F1-Score yang tinggi (0.99) pada kedua kelas menandakan keseimbangan yang baik antara precision dan recall, yang berarti model mampu mendeteksi kedua kelas dengan sangat akurat dan konsisten.

4.5.3 Rangkuman Pengujian Model

Dilihat dari Tabel 4.2 dan Tabel 4.4 pada model 1 menggunakan arsitektur CNN dengan dua blok Conv2D, di mana blok pertama memiliki 32 filter dan blok kedua memiliki 64 filter. Setiap blok konvolusi diikuti oleh lapisan MaxPooling2D untuk mereduksi dimensi spasial. Model ini menunjukkan akurasi yang sangat tinggi pada data pelatihan dan validasi, mencapai 100% pada data pelatihan dan sekitar 98% pada data validasi. Namun, model ini menunjukkan beberapa kesalahan pada pengujian, dengan 6 false positives dan 10 false negatives. Hasil ini menunjukkan bahwa meskipun model ini efektif dalam memprediksi kelas "Sehat" dan "Depresi", overfitting dan keragaman data EEG menjadi tantangan dalam generalisasi ke data yang tidak terlihat sebelumnya.

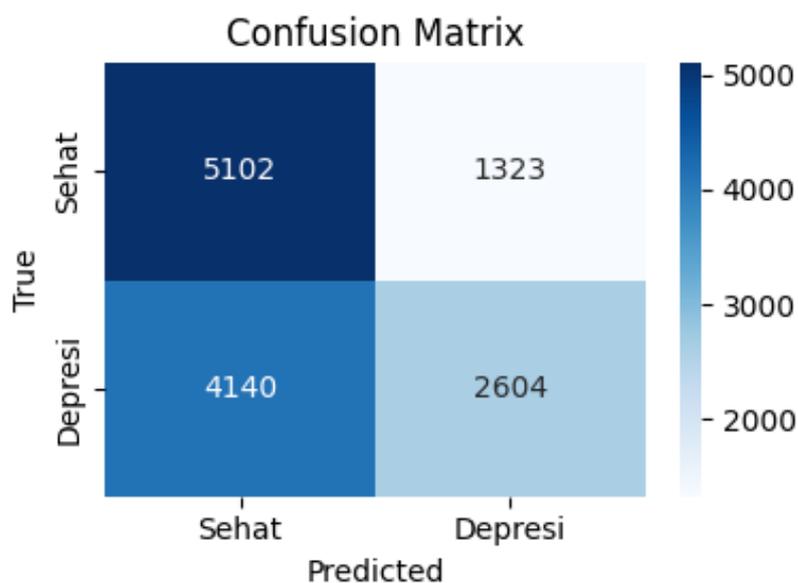
Pada model 2 memiliki arsitektur yang lebih dalam dengan tiga blok Conv2D, di mana filter bertambah seiring bertambahnya lapisan konvolusi. Model ini mencapai akurasi 99% pada kedua kelas, dengan precision dan recall yang sangat baik untuk kelas "Sehat" (0.98 dan 1.00) dan untuk kelas "Depresi" (1.00 dan 0.98). Model ini menunjukkan sedikit kesalahan pada pengujian, hanya 2 kesalahan pada kelas "Sehat" dan 11 kesalahan pada kelas "Depresi". Dengan hasil yang lebih stabil dan kesalahan yang lebih sedikit dibandingkan Model 1, Model 2 lebih unggul dalam mengenali pola pada data validasi dan pengujian,

4.6 Pengujian Menggunakan Dataset Dot Probe

Dataset yang digunakan adalah dimana peserta eksperimen diminta untuk duduk di depan monitor dengan jarak 60 cm, di mana mereka akan menjalani tugas yang melibatkan pasangan gambar wajah emosional-netral yang ditampilkan di layar. Sebelum eksperimen dimulai, peserta diberikan instruksi yang jelas yang ditampilkan di layar komputer dan diminta untuk menyelesaikan 10 latihan terlebih dahulu agar mereka bisa lebih mengenal tugas yang akan dijalankan. Selama eksperimen, peserta diminta untuk fokus memandangi gambar wajah yang menggambarkan berbagai emosi (takut, sedih, dan bahagia) serta gambar netral, dan tidak diperbolehkan melakukan gerakan tubuh seperti menggerakkan kepala, kaki, atau gerakan mata yang tidak perlu, seperti sakade atau berkedip, agar perhatian mereka tetap terfokus pada tugas. Ketika titik muncul di layar, peserta harus menekan tombol reaksi secepat dan seakurat mungkin untuk menentukan posisi titik yang muncul di kiri atau kanan layar. Eksperimen terdiri dari tiga blok, masing-masing berisi 160 percobaan, dengan gambar-gambar yang menunjukkan emosi berbeda seperti Fear-Neutral, Sad-Neutral, dan Happy-Neutral. Setiap percobaan dimulai dengan tampilan cross putih yang muncul selama 300 ms, diikuti dengan pasangan gambar wajah yang ditampilkan selama 500 ms. Setelah gambar-gambar tersebut, titik akan muncul secara acak di kiri atau kanan selama 150 ms, dan peserta diminta untuk menentukan posisi titik tersebut dengan menekan tombol '1' jika titik muncul di kiri, atau tombol '4' jika titik muncul di kanan. Jika peserta tidak merespons dalam waktu 2000 ms, percobaan akan langsung dilanjutkan ke percobaan berikutnya setelah layar hitam muncul selama 600 ms. Prosedur ini diulang hingga seluruh blok selesai, dengan total durasi eksperimen sekitar 25 menit.

4.6.1 Model 1

Model yang diuji pada dataset ini menunjukkan hasil yang beragam, dengan kinerja yang cukup baik pada beberapa aspek, namun juga terdapat kekurangan yang signifikan dalam memprediksi kelas "Depresi." Berdasarkan confusion matrix, model berhasil memprediksi 5102 data "Sehat" dengan benar (True Positive) dan 2604 data "Depresi" dengan benar (True Negative). Namun, model mengalami kesulitan dalam membedakan "Sehat" dan "Depresi," dengan kesalahan prediksi yang cukup besar. Sebagai contoh, ada 1323 data "Sehat" yang salah diprediksi sebagai "Depresi" (False Positive), dan 4140 data "Depresi" yang salah diprediksi sebagai "Sehat" (False Negative). Hal ini menunjukkan bahwa meskipun model cukup akurat dalam memprediksi "Sehat," model kesulitan dalam memprediksi "Depresi."



Gambar 4.18: Matrix Predicted Model 1

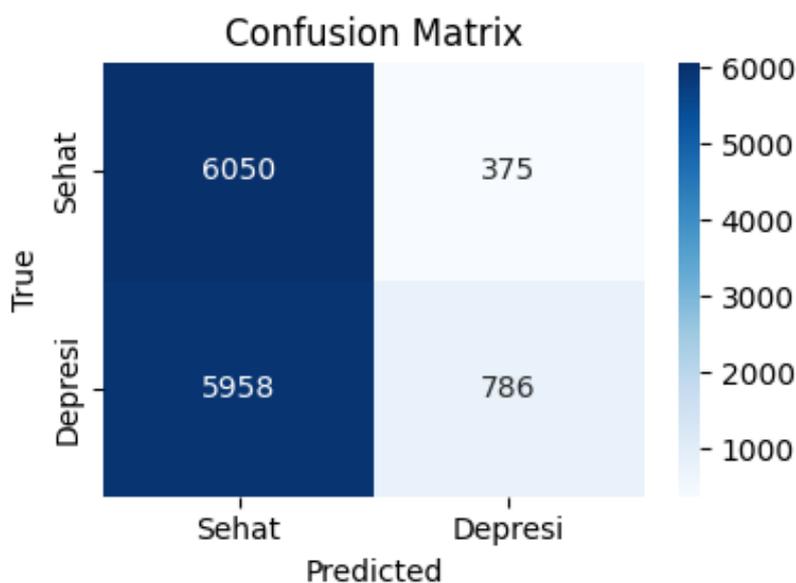
Tabel 4.5: Hasil Nilai Klasifikasi Model 1

Class	Accuracy	Precision	Recall	F1-Score
Sehat	0.59	0.55	0.79	0.65
Depresi	0.59	0.66	0.39	0.49

Dari laporan klasifikasi, dapat dilihat bahwa model memiliki presisi yang lebih tinggi untuk kelas "Depresi" (0.66) dibandingkan dengan "Sehat" (0.55), yang berarti model lebih sering benar saat memprediksi "Depresi." Namun, recall untuk "Depresi" sangat rendah (0.39), yang menunjukkan bahwa model sering melewati data "Depresi." Hal ini berbanding terbalik dengan recall untuk "Sehat" yang cukup tinggi (0.79), menunjukkan bahwa model lebih baik dalam mengenali kondisi "Sehat." Secara keseluruhan, model memiliki F1-Score yang lebih baik untuk "Sehat" (0.65) dibandingkan dengan "Depresi" (0.49). F1-Score ini menunjukkan bahwa meskipun model baik dalam mengidentifikasi "Sehat," model kesulitan untuk mengenali "Depresi."

4.6.2 Model 2

Model yang diuji memiliki kinerja yang sangat baik dalam mengenali data "Sehat" namun kurang efektif dalam mengidentifikasi data "Depresi." Berdasarkan confusion matrix, model berhasil memprediksi 6050 data "Sehat" dengan benar (True Positives) dan 786 data "Depresi" yang benar (True Negatives). Namun, model sering salah memprediksi data "Sehat" sebagai "Depresi" dan sebaliknya, data "Depresi" sebagai "Sehat," yang menunjukkan adanya kesalahan dalam klasifikasi. Recall untuk "Sehat" sangat tinggi (0.94), yang berarti model mampu mengidentifikasi sebagian besar data "Sehat," tetapi precision-nya hanya 0.50, yang artinya banyak prediksi "Sehat" yang salah.



Gambar 4.19: Matrix Predicted Model 2

Tabel 4.6: Hasil Nilai Klasifikasi Model 2

Class	Accuracy	Precision	Recall	F1-Score
Sehat	0.52	0.50	0.94	0.66
Depresi	0.52	0.68	0.12	0.20

Di sisi lain, kelas "Depresi" memiliki masalah yang lebih besar. Meskipun precision untuk "Depresi" cukup baik (0.68), recall-nya sangat rendah (0.12), yang berarti model sangat buruk dalam mendeteksi data yang benar-benar "Depresi." F1-score untuk "Depresi" pun hanya 0.20, yang menunjukkan ketidakseimbangan yang besar antara kemampuan model dalam memprediksi kelas "Depresi" dengan benar dan kemampuan model untuk mengidentifikasi semua data "Depresi" yang ada. Hal ini mengindikasikan bahwa model lebih sering memprediksi kelas "Sehat" dan kesulitan dalam mengenali data "Depresi."

4.6.3 Pembahasan Hasil Pengujian Dataset Berbeda

Dilihat dari Tabel 4.4 dan Tabel 4.6 pada model 1 yang dilatih menggunakan dataset resting state, menunjukkan hasil yang sangat baik dengan accuracy 0.98 pada kedua kelas, yaitu "Sehat" dan "Depresi." Precision dan recall untuk kedua kelas juga sangat tinggi, dengan F1-Score mencapai 0.98. Ini menunjukkan bahwa model ini sangat efektif dalam mendeteksi kedua kelas pada dataset resting state. Namun, saat diuji pada dataset activate state, model ini mengalami penurunan performa, terutama dalam mendeteksi kelas "Depresi," karena perbedaan karakteristik data yang lebih dinamis dan kompleks dalam activate state.

Model 2, yang juga dilatih menggunakan dataset resting state, menunjukkan kinerja yang hampir sempurna dengan accuracy 0.99, serta precision dan recall yang sangat tinggi untuk kedua kelas. F1-Score untuk kedua kelas mencapai 0.99, yang menandakan keseimbangan yang sangat baik antara presisi dan recall. Meskipun model ini berkinerja sangat baik pada dataset

resting state, model 2 juga kesulitan dalam mendeteksi pola pada dataset activate state, terutama dalam mengenali kelas "Depresi."

Secara keseluruhan, meskipun kedua model menunjukkan hasil yang luar biasa pada dataset resting state, performa mereka menurun saat diuji pada dataset activate state. Hal ini menunjukkan bahwa kedua model kesulitan dalam mengenali pola yang lebih kompleks dan dinamis dari data activate state. Untuk meningkatkan kinerja model pada dataset tersebut, perlu dilakukan pendekatan seperti transfer learning atau augmentasi data agar model lebih mampu beradaptasi dengan perbedaan karakteristik data antara resting state dan activate state.

[Halaman ini sengaja dikosongkan]

BAB V

PENUTUP

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa metode klasifikasi menggunakan model Convolutional Neural Network (CNN) untuk deteksi kondisi “Sehat” dan “Depresi” pada sinyal EEG telah berhasil diimplementasikan dengan baik. Model 2, yang memiliki arsitektur lebih dalam dan menggunakan teknik regularisasi seperti dropout, menunjukkan hasil yang sangat baik dengan akurasi mencapai 99% pada kedua kelas. Hal ini menunjukkan kemampuan model dalam mengenali pola pada data EEG secara efektif dan stabil. Namun, pengujian pada dataset yang activate state menunjukkan penurunan performa, yang menandakan bahwa model masih kesulitan untuk mengenali pola yang lebih kompleks dan bervariasi. Perbandingan antara Model 1 dan Model 2 menunjukkan bahwa model dengan arsitektur yang lebih dalam lebih efektif dalam mengurangi overfitting dan dapat menggeneralisasi data dengan lebih baik. Meskipun Model 1 menunjukkan kinerja yang baik pada data pelatihan dan validasi, Model 2 memiliki kestabilan dan akurasi yang lebih tinggi, khususnya pada dataset yang lebih bervariasi. Secara keseluruhan, meskipun CNN efektif, masih diperlukan perbaikan untuk meningkatkan kinerja pada data yang lebih variatif dan kompleks.

5.2 Saran

Untuk pengembangan lebih lanjut pada penelitian berikutnya adalah antara lain:

1. Mencoba menggunakan channel EEG selain yang digunakan (FT7, T7, TP7, TP8, T8, FT8, F3, F4) untuk menemukan kombinasi channel yang paling sensitif mendeteksi tanda-tanda depresi.
2. Selain Power Spectral Density, uji juga teknik ekstraksi fitur lain untuk melihat apakah ada pendekatan yang lebih efektif.
3. Melakukan pengujian pada kumpulan data EEG baru daripada hanya memecah dataset yang sama, agar mengetahui seberapa akurat model ketika dihadapkan pada kondisi nyata.

[Halaman ini sengaja dikosongkan]

DAFTAR PUSTAKA

- [1] Gonzalo Rojas, Carolina Álvarez, Carlos Montoya Moya, Maria de la Iglesia Vaya, Jaime Cisternas, and Marcelo Gálvez. Study of resting-state functional connectivity networks using eeg electrodes position as seed. *Frontiers in Neuroscience*, 12:235, April 2018.
- [2] Junxia Han, Guoqian Jiang, Gaoxiang Ouyang, and Xiaoli Li. A multimodal approach for identifying autism spectrum disorders in children. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30:1–1, 07 2022.
- [3] MathWorks. bandpass. <https://www.mathworks.com/help/signal/ref/bandpass.html>, n.d. Accessed: 2025-07-23.
- [4] Enrique Martínez Beltrán, Mario Quiles, Sergio López Bernal, Alberto Huertas, and Gregorio Martinez Perez. Noise-based cyberattacks generating fake p300 waves in brain–computer interfaces. *Cluster Computing*, 25, 02 2022.
- [5] Muchamad Kurniawan, Andy Rachman, and Adib Pakarbudi. Review pemanfaatan data electroencephalogram (eeg) dengan metode convolution neural network. *INTEGER: Journal of Information Technology*, 6(2):143–150, September 2021.
- [6] Stack Overflow Contributors. Does one convolutional filter always have different coefficients for each of the input channels? <https://stackoverflow.com/questions/44249115/does-one-convolutional-filter-always-have-different-coefficients-for-each-of-the-input-channels>, 2017. Accessed: 2025-07-23.
- [7] Davito Rasendriya Rizqullah Putra and Reyhan Adi Saputra. Implementasi convolutional neural network (cnn) untuk mendeteksi penggunaan masker pada gambar. *Jurnal Informatika dan Teknik Elektro Terapan*, 11(3), Aug. 2023.
- [8] Huo Yingge, Imran Ali, and Kang-Yoon Lee. Deep neural networks on chip - a survey. pages 589–592, 02 2020.
- [9] Sai Meruva, Venkata Tulasi, Nithin Vinnakota, and Bhavana V. Risk level prediction of diabetic retinopathy based on retinal images using deep learning algorithm. *Procedia Computer Science*, 215:722–730, 12 2022.
- [10] Chien-Te Wu, Daniel G. Dillon, Hao-Chun Hsu, Shiuan Huang, Elyssa Barrick, and Yi-Hung Liu. Depression detection using relative EEG power induced by emotionally positive images and a conformal kernel support vector machine. *Applied Sciences*, 8(8):1244, 2018.
- [11] World Health Organization. Depressive disorder (depression). <https://www.who.int/news-room/fact-sheets/detail/depression>, March 31 2023. Retrieved 31 March 2023.

- [12] Esmeralda C. Djamal and Harijono A. Tjokronegoro. Identifikasi dan klasifikasi sinyal eeg terhadap rangsangan suara dengan ekstraksi wavelet dan spektral daya. *Journal of Mathematical and Fundamental Sciences*, 37(1):69–92, December 2013.
- [13] Aldy Putra Wijaya. Pengembangan sistem pengenalan pergerakan prostetik tangan bionik menggunakan metode k-nearest neighbor dengan fitur power spectral density. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 8(6), July 2024.
- [14] Thariq Andhita Putera and Barlian Henryranu Prasetyo. Sistem deteksi depresi melalui pengenalan pola suara dengan mengimplementasikan metode prosody analysis. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 8(7), July 2024.
- [15] Lucas R. Trambaiolli and Claudinei E. Biazoli. Resting-state global eeg connectivity predicts depression and anxiety severity. In *Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 3707–3710, July 2020.
- [16] Mengqian Li, Yuan Liu, Yan Liu, Changqin Pu, Ruocheng Yin, Ziqiang Zeng, Libin Deng, and Xing Wang. Resting-state eeg-based convolutional neural network for the diagnosis of depression and its severity. *Frontiers in Physiology*, 13:956254, 2022.
- [17] Nursuci Putri Husain and Nurseno Bayu Aji. Klasifikasi sinyal eeg dengan power spectra density berbasis metode welch dan mlp backpropagation. *Jurnal ELTIKOM : Jurnal Teknik Elektro, Teknologi Informasi dan Komputer*, 3(1):17–25, May 2019.
- [18] Bingtao Zhang, Guanghui Yan, Zhifei Yang, Yun Su, Jinfeng Wang, and Tao Lei. Brain functional networks based on resting-state eeg data for major depressive disorder analysis and classification. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 29:215–229, March 2021.
- [19] Adhi Dharma Wibawa, Ulfi Widya Astuti, Nophaz Hanggara Saputra, Arbintoro Mas, and Yuri Pamungkas. Classifying stress mental state by using power spectral density of electroencephalography (eeg). In *Proceedings of the 14th International Conference on Information Technology and Electrical Engineering (ICITEE)*, pages 235–240, 2022.
- [20] Zhi Ying Ong, A. Saidatul, and Z. Ibrahim. Power spectral density analysis for human eeg-based biometric identification. In *Proceedings of the 2018 International Conference on Computational Approach in Smart Systems Design and Applications (ICASSDA)*, pages 1–6, 2018.
- [21] Agus Muliadi and Khairul Muttaqin. Filtering sinyal menggunakan bandpass filter. *Jurnal Informatika dan Teknologi Komputer*, 02(01):12–16, 2021.
- [22] MY Teguh Sulistyono, Dyah Ernawati, Stalina Anggraeny Dewi Amodia, and Davin Hernanda Putra. Segmentasi data sinyal eeg berdasarkan domain waktu sebagai dasar dalam pengolahan sinyal pengambilan keputusan dalam rehabilitasi stroke. *JOINS (Journal of Information System)*, 9(1):67–74, Jul. 2024.
- [23] Mengting He, Yunfei Wu, Zixuan Li, Shijian Wang, Wenjie Li, Wen Zhou, Haosen Rong, and Jianqing Wang. Hmt: An eeg signal classification method based on cnn architecture. In *Proceedings of the 5th International Conference on Intelligent Control, Measurement and Signal Processing (ICMSP)*, Shanghai, China, 2023. IEEE.

- [24] Indana Nihayatul Husna, Miftachul Ulum, Adi Kurniawan Saputro, Haryanto, Deni Tri Laksono, and Dian Neipa Purnamasari. Rancang bangun sistem deteksi dan perhitungan jumlah orang menggunakan metode convolutional neural network (cnn). *SinarFe7*, 5(1):1–6, December 2022.
- [25] Alexandre Gramfort, Martin Luessi, Eric Larson, Denis A. Engemann, Daniel Strohmeier, Christian Brodbeck, Roman Goj, Mainak Jas, Teon Brooks, Lauri Parkkonen, and Matti Hämäläinen. Meg and eeg data analysis with mne-python. *Frontiers in Neuroscience*, 7, 2013.

[Halaman ini sengaja dikosongkan]

BIOGRAFI PENULIS



Mida Hasian, atau yang biasa dikenal sebagai Mida, lahir di Jakarta pada 23 April 2002. Penulis merupakan anak pertama dari dua bersaudara yang tinggal dan tumbuh besar di Kota Tangerang Selatan. Ketertarikan mendalam penulis di bidang teknologi mengantarkan penulis yang telah menyelesaikan masa sekolah di SMA Negeri 12 Tangerang Selatan ke jenjang strata satu di Departemen Teknik Komputer Fakultas Teknologi Elektro dan Informatika Cerdas Institut Teknologi Sepuluh Nopember (ITS) pada tahun 2021.

Sejak awal perkuliahan, penulis memiliki ketertarikan dalam menjelajahi topik - topik yang berkaitan dengan bidang teknologi. Dalam masa kuliah, penulis tertarik dengan topik seperti *Internet Of Things* (IOT)

Dalam tugas akhir ini, penulis mengembangkan sistem klasifikasi kondisi depresi berdasarkan sinyal EEG dengan memanfaatkan ekstraksi Power Spectral Density (PSD), lalu diolah oleh arsitektur CNN 2D. Inspirasi muncul dari keprihatinan terhadap tingginya angka depresi dan kebutuhan akan deteksi dini yang non-invasif. Sistem yang dihasilkan diharapkan dapat membantu peneliti dan praktisi medis dalam mengenali pola-pola EEG khas depresi secara efektif.

[Halaman ini sengaja dikosongkan]