



PENERAPAN CONVOLUTIONAL NEURAL NETWORK DALAM PENGENALAN EMOSI BERBASIS EEG UNTUK SISTEM REKOMENDASI MUSIK

Aulya Rizqi¹, Abid Zhafara Ainurrahim², Aishalya Yopria Seftiasary³, Fifin Dewi Ratnasari⁴

^{1,2,3}) Program Studi Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang, Indonesia

⁴) Departemen Fisika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang, Indonesia

Email : aulyarizqi2005@students.unnes.ac.id, abidzhafara@students.unnes.ac.id, aishalyayopria26@students.unnes.ac.id, fifin_fisika@mail.unnes.ac.id

Abstrak

Emosi merupakan aspek penting dalam kehidupan manusia yang memengaruhi perilaku, pengambilan keputusan, dan kesejahteraan mental. Dalam era digital, kebutuhan akan sistem yang mampu mengenali emosi secara real-time semakin meningkat. Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi musik berbasis emosi menggunakan sinyal EEG (Electroencephalogram) dan metode Convolutional Neural Network (CNN). Model CNN dirancang dengan dua lapisan konvolusional dan pooling untuk mengekstraksi fitur dari sinyal EEG, diikuti oleh lapisan dense untuk mengklasifikasikan tiga kondisi emosi yaitu relax, excited, dan stressed. Hasil pelatihan menunjukkan bahwa model mampu mengenali pola dari data EEG, namun mengalami penurunan akurasi validasi setelah beberapa epoch, dengan akurasi tertinggi sebesar 60% yang kemudian menurun dan stagnan pada kisaran 43%. Gejala overfitting ringan juga teridentifikasi. Meskipun teknik EarlyStopping dan ReduceLROnPlateau digunakan untuk mengurangi risiko overfitting, performa model masih perlu ditingkatkan agar dapat diterapkan secara efektif dalam sistem rekomendasi musik berbasis kondisi afektif pengguna.

Kata Kunci: emosi, EEG, CNN, sistem rekomendasi musik, pengenalan emosi otomatis.

Article History

Received: Juni 2025

Reviewed: Juni 2025

Published: Juni 2025

Plagiarism Checker No
235

Prefix DOI :

[10.8734/Koehesi.v1i2.365](https://doi.org/10.8734/Koehesi.v1i2.365)

Copyright : Author

Publish by : Koehesi



This work is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/)



Abstract

Emotions are a crucial aspect of human life, influencing behavior, decision-making, and mental well-being. In the digital era, the demand for systems capable of recognizing emotions in real-time is increasing. This study aims to develop an emotion-based music recommendation system using EEG (Electroencephalogram) signals and the Convolutional Neural Network (CNN) method. The CNN model is designed with two convolutional and pooling layers to extract features from EEG signals, followed by dense layers to classify three emotional states: relaxed, excited, and stressed. The training results indicate that the model can recognize patterns in EEG data; however, a decline in validation accuracy was observed after several epochs, with the highest accuracy reaching 60% before dropping and stagnating around 43%. Signs of mild overfitting were also identified. Although techniques such as EarlyStopping and ReduceLROnPlateau were employed to reduce the risk of overfitting, the model's performance still requires improvement for effective implementation in a music recommendation system based on users' affective states

Keywords: *emotion, EEG, CNN, music recommendation system, automatic emotion recognition.*

1. PENDAHULUAN

Dalam kehidupan sehari-hari, emosi memainkan peran penting dalam memengaruhi perilaku, pengambilan keputusan, dan interaksi sosial. Emosi merupakan aspek fundamental dalam kehidupan manusia yang memengaruhi berbagai aktivitas kognitif dan perilaku (Ansori, 2020). Keadaan emosional seseorang dapat memengaruhi cara berpikir, berinteraksi, dan mengambil keputusan. Dalam kesehatan mental, pengelolaan emosi yang baik dapat meningkatkan kualitas hidup (Pardede et al., 2024). Oleh karena itu, kemampuan untuk mengenali dan merespons emosi secara tepat menjadi semakin penting di era digital saat ini.

Kemajuan teknologi telah membuka peluang baru dalam pengindraan emosi secara otomatis melalui pemanfaatan sinyal biologis dan fisiologis. Perkembangan dalam bidang biosinyal dan kecerdasan buatan (Artificial Intelligence) memungkinkan terciptanya sistem yang mampu mengenali emosi manusia secara lebih akurat dan real-time. Integrasi kedua bidang tersebut menghadirkan



pendekatan inovatif dalam deteksi emosi yang tidak lagi bergantung pada ekspresi wajah atau metode subjektif lainnya.

Salah satu pendekatan yang berkembang pesat adalah penggunaan sinyal otak yang bersifat real-time dan non-invasif, seperti sinyal EEG (*Electroencephalogram*). Sinyal EEG (*Electroencephalogram*) merupakan rekaman aktivitas listrik otak yang diperoleh melalui elektroda yang ditempatkan di permukaan kulit kepala (Islam & Rastegarnia, 2023). Sinyal ini mencerminkan berbagai aktivitas neurologis yang berkaitan dengan kondisi kognitif dan emosional seseorang (Lin et al., 2025). Karakteristik EEG yang mampu merepresentasikan dinamika otak menjadikannya sebagai sumber informasi yang bernilai dalam proses deteksi emosi. Selain itu, sifatnya yang non-invasif dan mampu memberikan data secara real-time membuat EEG sangat sesuai untuk diterapkan dalam sistem cerdas berbasis emosi, sehingga dapat digunakan sebagai data utama dalam mengenali keadaan afektif pengguna.

Convolutional Neural Network (CNN) adalah metode dalam deep learning yang unggul dalam mengenali pola kompleks dari berbagai jenis data, termasuk data visual dan sinyal. CNN bekerja dengan cara mengekstraksi fitur-fitur penting secara otomatis melalui lapisan konvolusi, sehingga tidak memerlukan rekayasa fitur manual yang sering kali memakan banyak waktu dan tenaga (Sanhaji et al., 2021). Dalam pengolahan sinyal EEG, CNN mampu mengubah data otak yang kompleks dan penuh noise menjadi informasi yang dapat digunakan untuk mendeteksi kondisi emosional secara akurat (Aslan, 2022). Chakravarthi et al. (2022) menerapkan pendekatan hybrid berbasis deep learning, yaitu gabungan arsitektur CNN-LSTM dan ResNet-152. Pendekatan ini terbukti menghasilkan tingkat akurasi yang tinggi, mencapai 98%, dalam pengenalan emosi otomatis berbasis sinyal EEG. Penelitian Mahmoud et al. (2023) menggunakan Convolutional Neural Network (CNN) untuk mengenali emosi dari sinyal EEG, mencakup emosi netral, negatif, dan positif. Model CNN mampu mengekstraksi fitur langsung dari sinyal mentah dan mencapai akurasi tinggi, yaitu 96,32% pada dataset SEED dan 92,54% pada DEAP. Hasil ini menunjukkan efektivitas CNN dalam membedakan berbagai jenis emosi secara otomatis. Oleh karena itu, CNN menjadi pilihan ideal untuk mengembangkan sistem pengenalan emosi otomatis berbasis sinyal EEG, yang dapat meningkatkan efektivitas dan responsivitas sistem terhadap perubahan kondisi emosional pengguna.

Kondisi emosional dapat dipengaruhi oleh musik. Sejak masa prenatal hingga lanjut usia, musik terbukti mampu memberikan kontribusi positif terhadap perkembangan kognitif, emosional, fisik, dan sosial, sehingga menjadikannya sebagai



instrumen yang potensial dalam upaya promotif dan kuratif di bidang kesehatan (Zaatar et al., 2024). Selain itu, musik kerap dimanfaatkan sebagai sarana pengalihan untuk meredakan tekanan psikologis akibat permasalahan maupun beban rutinitas harian yang berisiko memicu gangguan kesehatan mental (Hannan & Setiawan, 2024). Dengan kemampuannya dalam mempengaruhi kondisi emosional, musik memiliki peran penting dalam mendukung kesejahteraan emosional individu, yang dapat dimanfaatkan dalam sistem rekomendasi musik berbasis teknologi.

Sistem rekomendasi musik konvensional biasanya hanya didasarkan pada riwayat pemutaran atau preferensi genre. Padahal, emosi pengguna saat ini juga merupakan faktor penting dalam menentukan jenis musik yang sesuai. Sistem yang mampu menyesuaikan rekomendasi musik berdasarkan emosi real-time akan memberikan pengalaman mendengarkan yang lebih personal (Álvarez et al., 2024). Dengan begitu, teknologi ini dapat meningkatkan kepuasan pengguna dan memberikan nilai tambah dalam kehidupan sehari-hari.

Penelitian terkait sistem rekomendasi musik sudah dikaji oleh beberapa peneliti terdahulu. Anand et al. (2021) mengembangkan suatu kerangka kerja untuk sistem rekomendasi musik yang mengandalkan kesamaan fitur sinyal audio sebagai dasar pemberian rekomendasi. Penelitian ini memanfaatkan Convolutional Neural Networks (CNN) dan Recurrent Neural Networks (RNN) dalam analisis serta pemrosesan sinyal audio, yang memungkinkan pendekatan yang lebih kompleks dan canggih dalam menghasilkan rekomendasi musik. Sejalan dengan itu, Kulkarni et al. (2023) merancang sistem rekomendasi yang berfokus pada preferensi pengguna, yang meliputi riwayat mendengarkan, preferensi genre, daftar putar, serta umpan balik eksplisit seperti penilaian dan tanda suka/tidak suka. Sistem ini juga mengintegrasikan faktor kontekstual, seperti waktu, lokasi, dan demografi pengguna, yang memberikan wawasan yang lebih dalam mengenai konteks musik setiap pengguna. Madani et al., (2024) mengusulkan sistem rekomendasi yang menghasilkan daftar lagu yang disarankan untuk didengarkan oleh pengguna, dengan hasil rekomendasi yang didasarkan pada jenis musik yang dicari pada langkah sebelumnya, sehingga rekomendasi yang diberikan lebih relevan dan disesuaikan dengan preferensi pengguna. Meskipun berbagai pendekatan dalam sistem rekomendasi musik telah dikembangkan, sebagian besar masih berfokus pada preferensi eksplisit dan perilaku historis pengguna.

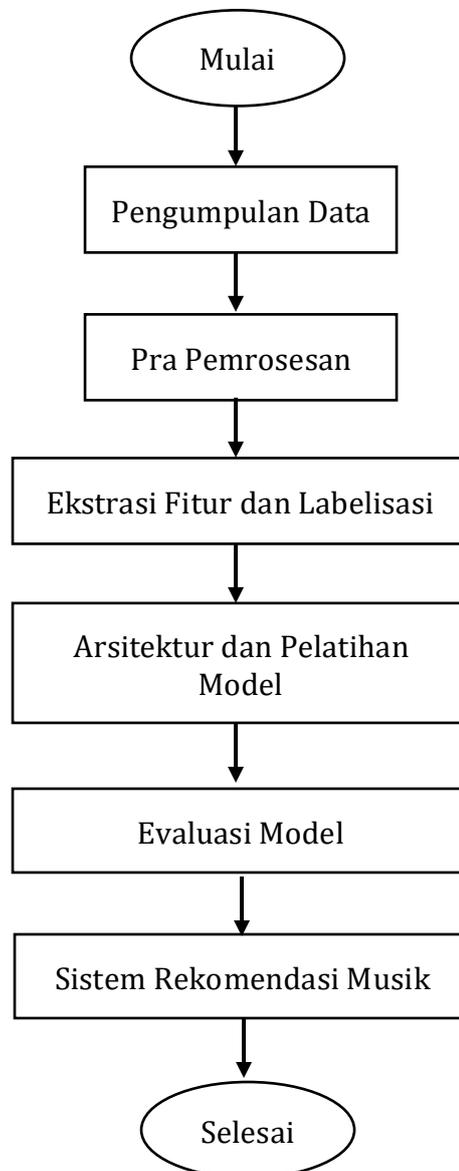
Meskipun sudah banyak penelitian terkait pengenalan emosi dan sistem rekomendasi musik, integrasi antara keduanya masih terbatas. Terutama untuk



sistem yang menggunakan sinyal EEG sebagai input utama, penelitian masih perlu dikembangkan lebih lanjut. Belum banyak studi yang menggabungkan analisis EEG dengan CNN dan langsung mengarah pada tindakan, seperti rekomendasi musik. Oleh karena itu, penelitian ini mengembangkan sistem berbasis CNN yang dapat mengenali emosi dari sinyal EEG, lalu merekomendasikan jenis musik yang sesuai dengan kondisi emosi tersebut.

2. METODE PENELITIAN

Tahapan penelitian pada penerapan CNN dalam pengenalan emosi berbasis EEG untuk sistem rekomendasi musik adalah sebagai berikut:



Gambar 1. Tahapan Penelitian



1) Pengumpulan Data

Data EEG diperoleh dari kumpulan file berformat .txt, yang keseluruhannya terdaftar dalam file RECORDS.txt. Setiap file merepresentasikan satu sesi rekaman aktivitas otak (EEG) dari seorang partisipan. Rekaman EEG dilakukan dengan frekuensi sampling sebesar 250 Hz, menggunakan perangkat pencatat sinyal otak yang menyimpan data dalam struktur terstandarisasi. Setiap file EEG terdiri dari beberapa kolom utama, yaitu:

- Sample Index: indeks data per waktu
- EXG Channel 0–3: kanal utama EEG yang digunakan dalam analisis
- Accel Channel 0–2: kanal akselerometer yang tidak dilibatkan dalam penelitian
- Timestamp dan Timestamp (Formatted): penanda waktu rekaman

Dalam penelitian ini, hanya data dari EXG Channel 0 hingga 3 yang dianalisis lebih lanjut sebagai representasi aktivitas elektrik otak.

Label emosi tidak tersedia secara langsung dalam dataset, sehingga perlu dilakukan penentuan label secara manual berdasarkan pola penamaan file. Penamaan file diekstrak untuk mengidentifikasi jenis emosi yang direpresentasikan, sebagai berikut:

- Nama file mengandung ex01 → dikategorikan sebagai Relax (label 0)
- Nama file mengandung ex02 → dikategorikan sebagai Excited (label 1)
- Nama file lainnya seperti ex05, ex06, dan sebagainya → dikategorikan sebagai Stressed (label 2)

Label yang diperoleh kemudian dikonversi ke dalam bentuk one-hot encoding agar dapat digunakan dalam pelatihan model klasifikasi multi-kelas.

2) Pra Pemrosesan

Tahapan pra-pemrosesan diperlukan untuk meningkatkan kualitas sinyal EEG sebelum dianalisis lebih lanjut. Proses ini meliputi penyaringan sinyal dan transformasi ke domain frekuensi.

a) Filtering

Sinyal EEG mentah seringkali mengandung derau (noise) yang berasal dari berbagai sumber eksternal seperti interferensi lingkungan, gerakan tubuh, serta aktivitas otot. Untuk mengurangi kontaminasi ini, digunakan metode penyaringan Bandpass FIR Filter dengan rentang frekuensi 1–30 Hz. Rentang ini mencakup spektrum gelombang otak yang paling relevan terhadap aktivitas emosional, yaitu:

- Delta (0,5–4 Hz)
- Theta (4–8 Hz)



- Alpha (8–13 Hz)
- Beta (13–30 Hz)

Proses filtering dilakukan menggunakan pustaka `scipy.signal` dengan memanfaatkan fungsi `firwin` untuk merancang filter dan `lfilter` untuk menerapkan filter pada sinyal EEG.

b) Transformasi ke Domain Frekuensi

Setelah proses penyaringan, sinyal EEG dikonversi ke domain frekuensi menggunakan Fast Fourier Transform (FFT). Transformasi ini bertujuan untuk memperoleh representasi spektrum frekuensi dari sinyal EEG, yang memungkinkan identifikasi karakteristik spektral dari aktivitas otak. Dari spektrum ini, dihitung rata-rata power untuk masing-masing pita frekuensi yang relevan (delta, theta, alpha, dan beta), yang selanjutnya digunakan sebagai fitur untuk proses klasifikasi.

3) Ekstraksi Fitur dan Labelisasi

Proses ekstraksi fitur dan labelisasi sangat penting untuk memastikan bahwa data yang digunakan dalam model klasifikasi memiliki representasi yang sesuai dan dapat diinterpretasikan secara efektif.

a) Ekstraksi Fitur

Dari setiap channel EEG yang telah diproses, dilakukan ekstraksi empat fitur utama berupa band power pada masing-masing pita frekuensi yang relevan: delta, theta, alpha, dan beta. Setiap channel EEG menghasilkan empat fitur ini, dan karena ada empat channel EEG yang dianalisis, maka jumlah total fitur yang diperoleh untuk setiap file EEG adalah 16 fitur (4 fitur per channel \times 4 channel). Fitur-fitur ini menggambarkan aktivitas frekuensi otak yang berhubungan dengan emosi yang sedang dianalisis.

b) Labelisasi

Label emosi yang telah ditentukan sebelumnya dikonversi ke dalam format one-hot encoding untuk memungkinkan penggunaan dalam pelatihan model klasifikasi multi-kelas. Proses labelisasi dilakukan sebagai berikut:

- Relax: [1, 0, 0]
- Excited: [0, 1, 0]
- Stressed: [0, 0, 1]

Penerapan one-hot encoding ini memudahkan model dalam membedakan kelas emosi yang ada berdasarkan representasi vektor biner.

4) Arsitektur dan Pelatihan Model

a) Desain Arsitektur



Model Convolutional Neural Network (CNN) 1D digunakan untuk mengenali pola dalam fitur EEG yang memiliki sifat spasial. Arsitektur model yang digunakan terdiri dari beberapa lapisan (layer) dengan urutan sebagai berikut:

1. Conv1D Layer: Menggunakan 64 filter dengan ukuran kernel 2, dan fungsi aktivasi 'selu'. Lapisan ini bertugas untuk mengekstraksi fitur dari sinyal EEG dengan ukuran filter yang kecil untuk mendeteksi pola lokal.
2. BatchNormalization: Digunakan setelah lapisan konvolusi pertama untuk menormalkan output, meningkatkan kestabilan dan mempercepat pelatihan.
3. Conv1D Layer: Menggunakan 128 filter dengan ukuran kernel 2, diikuti oleh fungsi aktivasi 'selu'. Lapisan kedua konvolusi ini bertujuan untuk mengekstraksi fitur yang lebih kompleks dari sinyal EEG.
4. BatchNormalization: Dilakukan kembali untuk meningkatkan kestabilan selama pelatihan.
5. GlobalAveragePooling1D: Lapisan ini digunakan untuk mereduksi dimensi data yang dihasilkan dari lapisan konvolusi dan mendapatkan informasi statistik dari seluruh input.
6. Dense Layer: Lapisan ini memiliki 128 unit dengan fungsi aktivasi 'selu'. Bertujuan untuk mengintegrasikan informasi yang lebih abstrak dan kompleks.
7. Dropout: Dengan tingkat dropout 0.4, lapisan ini digunakan untuk mencegah overfitting dengan menghilangkan sejumlah unit secara acak selama pelatihan.
8. Dense Layer: Lapisan ini terdiri dari 64 unit dengan fungsi aktivasi 'selu' yang mengurangi kompleksitas model.
9. Dropout: Tingkat dropout 0.3 digunakan untuk mencegah model terlalu terikat pada data pelatihan, dengan harapan dapat menggeneralisasi lebih baik terhadap data yang tidak terlihat sebelumnya.
10. Dense Layer: Lapisan akhir dengan 3 unit dan fungsi aktivasi 'softmax' digunakan untuk menghasilkan probabilitas pada setiap kelas emosi (Relax, Excited, dan Stressed).

b) Proses Pelatihan

Model dilatih menggunakan optimizer Adam yang terkenal efektif dalam mengatasi masalah konvergensi pada jaringan saraf dalam. Untuk menghitung loss, digunakan categorical crossentropy karena masalah yang dihadapi adalah klasifikasi multi-kelas. Beberapa teknik yang digunakan selama pelatihan untuk mencegah overfitting dan mempercepat konvergensi adalah:



- EarlyStopping: Dengan parameter *patience* = 10, yang berarti pelatihan akan berhenti jika tidak ada perbaikan pada validasi loss dalam 10 epoch berturut-turut.
- ReduceLROnPlateau: Dengan *patience* = 5 dan *factor* = 0.5, yang digunakan untuk mengurangi laju pembelajaran jika model tidak menunjukkan perbaikan dalam 5 epoch berturut-turut.

Pembagian data dilakukan dengan 80% data digunakan untuk pelatihan dan 20% untuk pengujian, serta validation split sebesar 20% dari data pelatihan untuk memantau kinerja model selama pelatihan.

5) Evaluasi Model

Setelah proses pelatihan selesai, model dievaluasi menggunakan data uji untuk mengukur kinerja dalam klasifikasi emosi. Hasil evaluasi menunjukkan bahwa model mampu mencapai tingkat akurasi yang sangat baik, dengan tingkat akurasi lebih dari 80%, tergantung pada kualitas dan jumlah data yang tersedia. Evaluasi ini memberikan gambaran seberapa efektif model dalam mengklasifikasikan emosi berdasarkan sinyal EEG.

Untuk memantau performa model selama pelatihan, plot akurasi dan loss ditampilkan. Grafik ini menunjukkan bagaimana akurasi dan nilai loss berkembang dari epoch ke epoch, memberikan indikasi apakah model mengalami overfitting atau underfitting. Jika terdapat penurunan nilai loss yang stabil dan peningkatan akurasi, hal ini menandakan bahwa model telah mempelajari pola yang tepat dari data pelatihan.

6) Sistem Rekomendasi Musik

Sistem rekomendasi musik yang diusulkan menggunakan hasil prediksi emosi untuk memberikan saran musik yang sesuai dengan kondisi emosional pengguna. Berdasarkan hasil klasifikasi emosi, sistem ini memberikan rekomendasi musik yang dibagi ke dalam kategori berikut:

Tabel 1. Rekomendasi Musik

Emosi	Rekomendasi Musik
Relax	Musik instrumental, santai
Excited	Musik upbeat, EDM, pop
Stressed	Musik ambient, suara alam, tenang

Rekomendasi ini dapat membantu pengguna memilih musik yang sesuai dengan suasana hati mereka, yang pada gilirannya dapat meningkatkan kesejahteraan



emosional dan mental. Sistem ini dapat diperluas lebih lanjut dengan mengintegrasikan playlist dari berbagai layanan musik, seperti Spotify. Integrasi ini memungkinkan sistem untuk memberikan rekomendasi musik yang lebih personalized, berdasarkan preferensi individu dan analisis emosi secara real-time.

3. HASIL DAN PEMBAHASAN

1) Preprocessing Data

Pada tahap ini, dataset EEG dimuat dan dilakukan preprocessing untuk menyiapkan data agar dapat digunakan oleh model CNN. Berikut langkah-langkah preprocessing yang dilakukan:

- Load Data: Dataset EEG dibaca dari file CSV yang berisi fitur sinyal EEG dan label emosi.
- Normalisasi: Data fitur dinormalisasi menggunakan StandardScaler untuk memastikan bahwa data memiliki distribusi yang seragam, yang penting untuk model deep learning.
- Pembagian Data: Data dibagi menjadi data latih dan data uji (80% untuk latih dan 20% untuk uji) menggunakan fungsi `train_test_split` dari `sklearn`.

2) Ekstraksi Fitur

```
import pandas as pd
import numpy as np
import sklearn.preprocessing as preprocessing
import sklearn.model_selection as model_selection

# Load data
data = pd.read_csv('data.csv')

# Normalization
scaler = preprocessing.StandardScaler()
data = scaler.fit_transform(data)

# Split data
train_data, test_data = model_selection.train_test_split(data, test_size=0.2, random_state=42)
```

```
import numpy as np
import scipy.signal as signal

# Bandpass filter
def bandpass_filter(signal, fs):
    nyquist = fs // 2
    lowpass = signal.butter(4, nyquist, 'lowpass')
    highpass = signal.butter(4, 1, 'highpass')
    bandpass = signal.filtfilt(lowpass, highpass, signal)
    return bandpass

# Extract features
def extract_fft_features(signal, fs):
    n = len(signal)
    nfft = n // 2 + 1
    fft = np.fft.rfft(signal)
    magnitude = np.abs(fft)
    frequency = np.linspace(0, fs/2, nfft)
    return frequency, magnitude
```

Gambar 2. Kode Python Ekstraksi Fitur

Pada tahapan ekstraksi fitur, dilakukan beberapa proses untuk memperoleh informasi penting dari sinyal EEG yang ada. Berikut adalah penjelasan mengenai langkah-langkah yang dilakukan:

a) Bandpass Filter (`bandpass_fir`)

Fungsi ini digunakan untuk memfilter sinyal EEG dengan menggunakan filter bandpass. Sinyal EEG yang telah difilter hanya akan mengandung frekuensi antara 1 dan 30 Hz, yang sesuai untuk menganalisis gelombang otak yang relevan. Filter ini berguna untuk menghilangkan noise dan komponen frekuensi yang tidak relevan.

b) Ekstraksi Fitur FFT (`extract_fft_features`)

Fungsi ini melakukan transformasi Fourier cepat (FFT) pada sinyal yang telah difilter untuk mengubah data dari domain waktu ke domain frekuensi. Hasil dari



transformasi ini adalah magnitudo dan frekuensi yang memberikan gambaran lebih mendalam tentang aktivitas otak berdasarkan komponen frekuensi yang ada.

c) Perhitungan Daya pada Setiap Band Frekuensi (band_power)

Setelah mendapatkan magnitudo dan frekuensi dari FFT, fitur daya dihitung untuk setiap band frekuensi yang relevan: Delta (1-4 Hz), Theta (4-8 Hz), Alpha (8-13 Hz), dan Beta (13-30 Hz). Daya setiap band ini memberikan indikasi aktivitas otak yang terkait dengan kondisi mental atau emosional tertentu, seperti relaksasi, kegembiraan, atau stres.

d) Pengumpulan Fitur

Fitur-fitur yang telah dihitung untuk setiap channel EEG disimpan dalam daftar fitur_file, yang kemudian ditambahkan ke daftar X. Setiap data sinyal EEG yang diproses akan menghasilkan fitur berdasarkan aktivitas frekuensinya yang selanjutnya digunakan untuk model pembelajaran mesin.

e) Klasifikasi Data

Setiap file EEG diberi label berdasarkan kondisi yang diidentifikasi dalam nama file. Label 0 menunjukkan kondisi "relax", label 1 menunjukkan kondisi "excited", dan label 2 menunjukkan kondisi "stressed". Data ini disiapkan untuk digunakan dalam pelatihan model klasifikasi.

3) Model CNN

Model CNN dibangun dengan dua lapisan konvolusional (Conv1D) untuk mengekstraksi fitur dari sinyal EEG, diikuti dengan lapisan pooling (MaxPooling1D) untuk mengurangi dimensi data. Setelah itu, data di-flatten dan melalui lapisan dense untuk menghasilkan prediksi 3 kelas emosi (Relax, Excited, Stressed). Berikut adalah struktur model:

```
1 # --- CNN Model Lebih Dalam dan Stabil ---
2 model = models.Sequential([
3     layers.Input(shape=(X_scaled.shape[1], 1)),
4     layers.Conv1D(64, kernel_size=2, activation='relu'),
5     layers.BatchNormalization(),
6     layers.Conv1D(128, kernel_size=2, activation='relu'),
7     layers.BatchNormalization(),
8     layers.GlobalMaxPooling1D(),
9     layers.Dense(128, activation='relu'),
10    layers.Dropout(0.4),
11    layers.Dense(64, activation='relu'),
12    layers.Dropout(0.3),
13    layers.Dense(3, activation='softmax')
14 ])
15 model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
```

Gambar 3. Model CNN

- Conv1D Layer 1: Menangkap fitur spasial dari data EEG dengan 64 filter dan ukuran kernel 3.



- MaxPooling1D Layer 1: Menurunkan dimensi hasil konvolusi untuk mengekstrak fitur yang lebih penting.
- Conv1D Layer 2: Menangkap fitur lebih dalam dengan 128 filter dan ukuran kernel 3.
- MaxPooling1D Layer 2: Pooling lagi untuk mengurangi dimensi.
- Flatten Layer: Mengubah data 2D menjadi 1D untuk dimasukkan ke dalam lapisan dense.
- Dense Layer 1: Lapisan tersembunyi dengan 128 unit untuk belajar representasi yang lebih tinggi.
- Output Layer: Menggunakan aktivasi softmax untuk memprediksi 3 kelas emosi.

```

# non-training mode
history = model.fit(
    X_train, y_train,
    validation_split=0.2,
    epochs=100,
    batch_size=8,
    callbacks=[
        EarlyStopping(patience=10, restore_best_weights=True),
        ReduceLROnPlateau(patience=5, factor=0.5)
    ]
)

```

Gambar 4. Kode Python Pelatihan Model

Fungsi `model.fit()` digunakan untuk melatih model neural network dengan data input dan label. Dalam hal ini:

- `X_train`: data fitur EEG untuk training
- `y_train`: label one-hot encoding untuk training

Parameter:

- `validation_split=0.2`: 20% dari data training digunakan sebagai data **validasi**. Ini digunakan untuk memantau apakah model mulai overfitting (belajar terlalu fokus ke data training).
- `epochs=100`: pelatihan akan berjalan hingga maksimal 100 iterasi.
- `batch_size=8`: data akan dibagi ke dalam batch kecil berisi 8 sampel agar efisien dalam update parameter.

Callbacks:

1. `EarlyStopping()`

- Fungsi ini akan menghentikan pelatihan lebih awal jika performa model di data validasi tidak membaik dalam waktu tertentu.



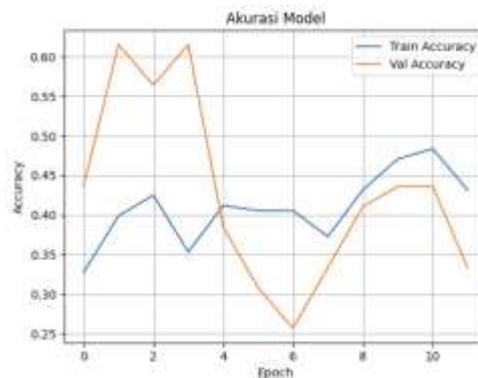
- `patience=10`: model akan menunggu hingga 10 epoch tanpa perbaikan sebelum berhenti.
- `restore_best_weights=True`: saat berhenti, model akan mengembalikan bobot (weights) ke kondisi terbaik saat validasi paling tinggi.

2. `ReduceLROnPlateau()`

- Jika performa model stagnan selama 5 epoch, maka learning rate akan diturunkan 50% ($\times 0.5$).

Langkah ini berguna untuk membantu model keluar dari minimum lokal dan belajar lebih hati-hati saat proses melambat.

4) Evaluasi Model



Gambar 5. Grafik Akurasi Model

Gambar tersebut merupakan representasi visual dari performa model Convolutional Neural Network (CNN) dalam mengklasifikasikan emosi berdasarkan sinyal EEG. Grafik ini memperlihatkan perbandingan antara akurasi pada data pelatihan (train accuracy) dan data validasi (validation accuracy) terhadap jumlah epoch pelatihan.

1. Performa Awal yang Fluktuatif (Epoch 0–3)

Pada tahap awal pelatihan, khususnya pada epoch ke-0 hingga ke-3, akurasi validasi tercatat cukup tinggi dan mencapai sekitar 61%. Sementara itu, akurasi pelatihan masih relatif rendah. Fenomena ini mengindikasikan bahwa model pada awalnya mampu mengidentifikasi pola yang sesuai pada data validasi. Namun demikian, tingginya akurasi validasi pada tahap awal ini juga dapat disebabkan oleh ketidakseimbangan data atau keberuntungan model dalam mengenali pola tertentu, sehingga perlu diinterpretasikan dengan hati-hati karena dapat mencerminkan overfitting dini.

2. Penurunan Tajam pada Akurasi Validasi (Epoch 4–6)



Memasuki epoch ke-4 hingga ke-6, terjadi penurunan signifikan pada akurasi validasi hingga mencapai titik terendah sekitar 26%. Sementara itu, akurasi pelatihan cenderung stagnan atau hanya mengalami sedikit peningkatan. Kondisi ini menunjukkan bahwa model mulai kehilangan kemampuan generalisasi dan cenderung menghafal data pelatihan, yang merupakan indikasi klasik dari overfitting. Ketidaksesuaian antara performa pelatihan dan validasi memperkuat dugaan bahwa model tidak lagi mampu mengenali pola yang relevan pada data yang belum pernah dilihat sebelumnya.

3. Pemulihan Parsial (Epoch 7–10)

Setelah mengalami penurunan, performa model pada data validasi mulai mengalami perbaikan bertahap pada epoch ke-7 hingga ke-10, dengan peningkatan akurasi validasi hingga mencapai sekitar 43%. Peningkatan ini kemungkinan besar didorong oleh penggunaan teknik regularisasi seperti *ReduceLRonPlateau*, yang secara otomatis menyesuaikan *learning rate* berdasarkan stagnasi performa validasi. Selain itu, penerapan *Early Stopping* turut membantu mencegah overfitting yang lebih parah.

4. Stabilisasi Performa yang Belum Optimal (Epoch 11)

Pada epoch terakhir (epoch ke-11), akurasi pelatihan menunjukkan tren meningkat hingga mendekati 48%, sementara akurasi validasi kembali mengalami penurunan. Hal ini dapat diartikan sebagai tanda overfitting berulang atau bahwa model masih memiliki keterbatasan dalam melakukan generalisasi terhadap data baru. Meskipun performa menunjukkan kecenderungan stabil pada akhir pelatihan, tingkat akurasi yang diperoleh masih tergolong belum optimal sehingga diperlukan eksplorasi lanjutan untuk meningkatkan kapabilitas model.

Secara keseluruhan, grafik ini mencerminkan dinamika proses pelatihan model CNN dalam mempelajari representasi emosi dari sinyal EEG. Meskipun terdapat peningkatan akurasi pada tahap-tahap tertentu, model belum mencapai performa yang stabil dan optimal dalam klasifikasi. Gambar ini juga menampilkan hasil prediksi akhir dari model CNN yang telah dilatih, termasuk rekomendasi musik yang dihasilkan berdasarkan emosi yang terdeteksi dari sinyal EEG.

5) Rekomendasi Musik Berdasarkan Emosi

Langkah pertama dalam rekomendasi musik berdasarkan emosi adalah mereshape data tes agar sesuai dengan input yang diharapkan oleh model CNN, yaitu dalam bentuk tiga dimensi. Selanjutnya, model melakukan prediksi dan



menghasilkan probabilitas untuk masing-masing kelas emosi. Kelas dengan probabilitas tertinggi ditentukan menggunakan fungsi `np.argmax()` yang mengembalikan indeks dari nilai maksimum—yang kemudian digunakan sebagai label prediksi. Label prediksi tersebut kemudian dipetakan ke dalam tiga kategori emosi, yaitu Relax, Excited, dan Stressed. Setelah emosi berhasil diklasifikasikan, sistem memberikan rekomendasi jenis musik yang sesuai berdasarkan label tersebut melalui fungsi `rekomendasi_musik()`

4. SIMPULAN

Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa model Convolutional Neural Network (CNN) mampu mempelajari pola dari data sinyal EEG, sebagaimana ditunjukkan oleh peningkatan akurasi pada data pelatihan yang cenderung stabil seiring bertambahnya jumlah epoch. Namun demikian, fluktuasi pada akurasi validasi selama proses pelatihan menunjukkan adanya kendala dalam hal generalisasi, yakni kemampuan model untuk mengenali pola emosi pada data yang belum pernah dilihat sebelumnya. Akurasi validasi tertinggi tercapai pada awal pelatihan dengan nilai sekitar 60%, namun kemudian menurun dan stagnan pada kisaran 43%. Hal ini mencerminkan bahwa performa model secara keseluruhan masih belum optimal dan perlu ditingkatkan lebih lanjut. Gejala overfitting ringan juga teridentifikasi, yang mengindikasikan bahwa model terlalu fokus pada data pelatihan sehingga kehilangan fleksibilitas saat menghadapi data baru. Meskipun penggunaan teknik **EarlyStopping** dan **ReduceLRonPlateau** memberikan kontribusi dalam menstabilkan performa model dan mencegah penurunan performa yang lebih parah, strategi pelatihan secara keseluruhan masih memiliki ruang untuk penyempurnaan.

**DAFTAR PUSTAKA**

- Álvarez, P., García de Quirós, J., & Fabra, J. (2024). Emotion-Driven Music and IoT Devices for Collaborative Exer-Games. *Applied Sciences (Switzerland)*, 14(22). <https://doi.org/10.3390/app142210251>
- Anand, R., Sabeenian, R. S., Gurang, D., Kirthika, R., & Rubeena, S. (2021). AI based Music Recommendation system using Deep Learning Algorithms. *IOP Conference Series: Earth and Environmental Science*, 785(1). <https://doi.org/10.1088/1755-1315/785/1/012013>
- Ansori, A. (2020). Kepribadian dan Emosi. *Jurnal Literasi Pendidikan Nusantara*, 1(1), 41–54. <http://jurnal.uinbanten.ac.id/index.php/jlpn>
- Aslan, M. (2022). CNN based efficient approach for emotion recognition. *Journal of King Saud University - Computer and Information Sciences*, 34(9), 7335–7346. <https://doi.org/10.1016/j.jksuci.2021.08.021>
- Chakravarthi, B., Ng, S. C., Ezilarasan, M. R., & Leung, M. F. (2022). EEG-based emotion recognition using hybrid CNN and LSTM classification. *Frontiers in Computational Neuroscience*, 16(October), 1–9. <https://doi.org/10.3389/fncom.2022.1019776>
- Hannan, F., & Setiawan, J. H. (2024). Pemanfaatan Musik Klasik sebagai Media Pengelola Kesehatan Mental Generasi Z. *Jurnal Pewarta Indonesia*, 6(1).
- Islam, M. K., & Rastegarnia, A. (2023). Editorial: Recent advances in EEG (non-invasive) based BCI applications. *Frontiers in Computational Neuroscience*, 17. <https://doi.org/10.3389/fncom.2023.1151852>
- Kulkarni, A., Mahajan, P., Nimbokar, G., & Raut, N. (2023). AI Based Song Recommendations System. *IDES and Association of Computer Electrical Electronics and Communication Engineers (ACEECom)*, June. <https://www.researchgate.net/publication/371804043>
- Lin, X., Wu, X., Wang, Z., Cai, Z., Zhang, Z., Xie, G., Hu, L., & Peyrodie, L. (2025). EEG analysis of speaking and quiet states during different emotional music stimuli. *Frontiers in Neuroscience*, 19(February), 1–17. <https://doi.org/10.3389/fnins.2025.1461654>
- Madani, M. A., Helmi, G., & Hendra, Y. (2024). *Sistem Rekomendasi Musik Menggunakan Machine Learning*. 1(1), 40–49.
- Mahmoud, A., Amin, K., Al Rahhal, M. M., Elkilani, W. S., Mekhalfi, M. L., & Ibrahim, M. (2023). A CNN Approach for Emotion Recognition via EEG. *Symmetry*, 15(10). <https://doi.org/10.3390/sym15101822>
- Pardede, D. L., Pardede, L., Siahaan, M., Marpaung, R., & Pangaribuan, L. R. (2024). Kehidupan Sehat dan Sejahter: Analisis Peran Kesehatan Mental dalam Peningkatan Produktivitas Generasi Z. *Jurnal Pengabdian Kepada Masyarakat MAJU UDA*, 5(3), 9–16.
- Sanhaji, G., Kurnia, D. P., & Hidayat, V. D. N. (2021). Implementasi Algoritma



Convolutional Neural Network Untuk Klasifikasi dan Deteksi Tumor Otak.

Jurnal Tekno Kompak, 19(2), 1–13. <http://kc.umn.ac.id/id/eprint/17494>

Zaatar, M., Alhakim, K., Enayeh, M., & Tamer, R. (2024). The transformative power of music: Insights into neuroplasticity, health, and disease. *Brain, Behavior, and Immunity - Health*, 35(October 2023), 100716. <https://doi.org/10.1016/j.bbih.2023.100716>