


BAB III

METODOLOGI PENELITIAN

3.1 Peta Jalan (Road Map) Penelitian



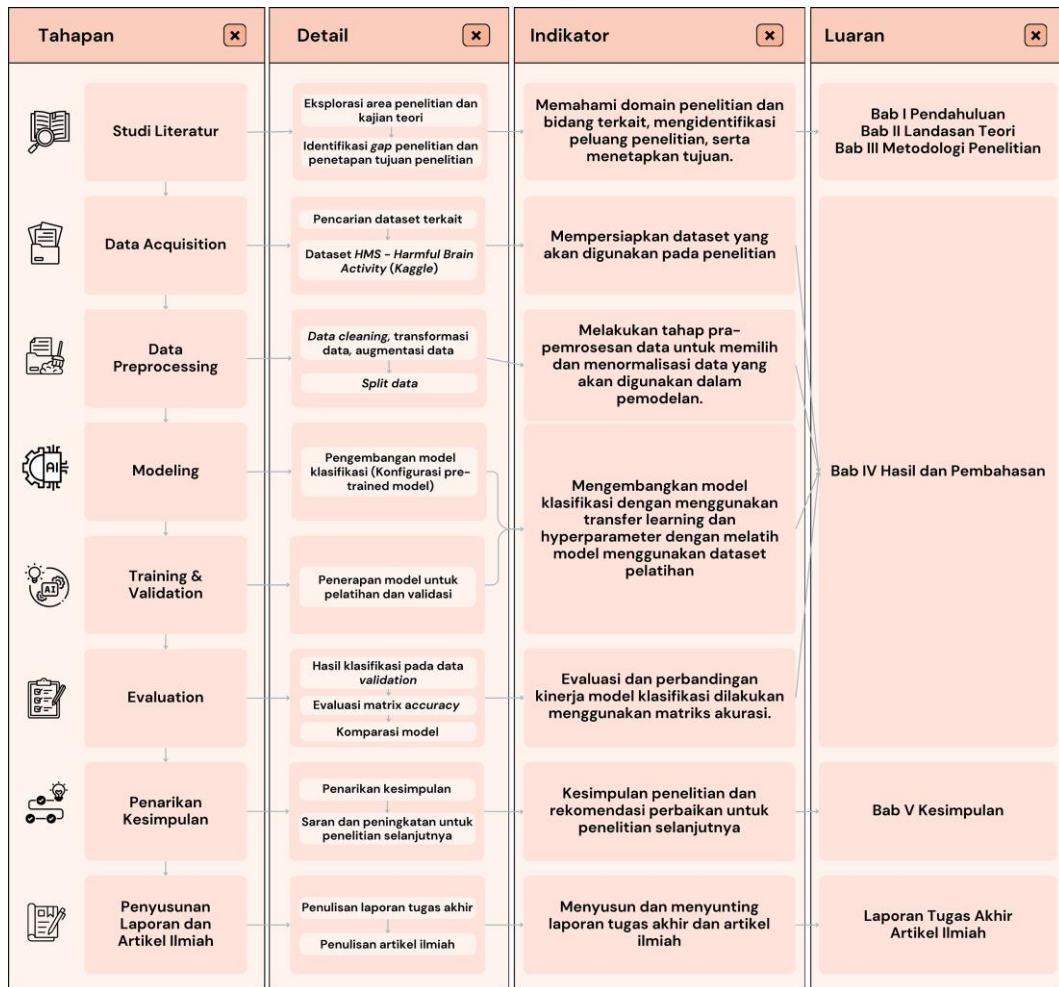
Gambar 3. 1 Peta Jalan KK ISI

Penelitian yang dijelaskan dalam proposal ini merupakan bagian dari Kelompok Keahlian Informatika dan Sistem Cerdas (KK ISI) Universitas Siliwangi. Roadmap penelitian KK ISI Universitas Siliwangi yang berkolaborasi dengan *AI Research Group Siliwangi University* diilustrasikan pada Gambar 3.1. Sebagai arah penelitian di bidang kecerdasan buatan (AI), spesifikasi dari setiap lapisan yang ditandai dengan kotak merah pada Gambar 3.1 akan digunakan dalam penelitian ini. Penelitian ini secara khusus berkaitan dengan bidang *machine learning, computer vision, classification and clustering* untuk mencapai tujuan akhir berupa *intelligent knowledge system*.


3.2 Tahapan Penelitian

Tahapan penelitian yang diterapkan dimulai dengan tahap studi literatur, akuisisi data, *preprocessing data, modeling*, pelatihan dan validasi model, serta evaluasi kinerja model. Rangkaian tahapan penelitian ini dapat diilustrasikan dalam Gambar 3.2.

Tujuan dari penelitian ini juga direpresentasikan dalam *Ishikawa Diagram* atau biasa dikenal sebagai *Fishbone Diagram*, yang merupakan alat yang sangat berguna untuk mengidentifikasi dan mengkategorikan akar penyebab potensial dari suatu masalah atau peristiwa (Varsha & Siddhi, 2015). Dengan memetakan secara visual berbagai faktor yang mungkin berkontribusi terhadap masalah yang dihadapi, diagram *fishbone* memungkinkan para peneliti untuk menggali lebih dalam untuk memahami penyebab utamanya. Pendekatan sistematis ini membantu tidak hanya dalam menentukan sumber potensial masalah tetapi juga dalam merumuskan strategi yang efektif untuk penyelesaiannya (Coccia, 2020).



Gambar 3. 2 Metodologi Penelitian

Gambar 3. 3 Diagram *Fishbone*

Gambar 3.3 menggambarkan tujuan utama dari penelitian ini menggunakan *fishbone diagram*, yaitu implementasi model yang dikembangkan dengan metode transfer learning untuk klasifikasi aktivitas otak berpotensi berbahaya. Bagian “ekor” dari diagram mewakili objek penelitian, yaitu Aktivitas Otak Berbahaya, sementara pada bagian “kepala” dilakukan implementasi transfer learning untuk klasifikasi aktivitas otak berbahaya. Pada bagian “tulang” dari diagram dapat dideksripsikan sebagai berikut:

- a. *Environment Research*, merupakan area penelitian yang akan menjadi fokus penelitian, yaitu dalam lingkup *deep learning* khususnya pada klasifikasi.
- b. *Material*, sumber data yang digunakan dalam penelitian ini adalah *dataset EEG* dan spektogram dari pasien kritis yang menunjukkan aktivitas otak berbahaya.
- c. *Measurement*, merupakan tahapan persiapan data sebelum dilakukan pengujian, yang melibatkan proses *preprocessing data*.
- d. *Machine*, merupakan perangkat atau alat yang digunakan dalam penelitian, yaitu dengan memanfaatkan *Kaggle Notebook* dan *Google Colab* sebagai platform komputasi.
- e. *Methods*, merupakan teknik atau algoritma yang akan digunakan dalam penelitian ini, mencakup pemanfaatan teknik *transfer learning* dengan model *pre-trained EfficientNetV2*, penerapan teknik augmentasi data.

3.3.1 Studi Literatur

Pada tahap studi literatur, dilakukan kajian terhadap berbagai sumber informasi, termasuk jurnal penelitian, buku, situs web resmi, dan laporan penelitian yang terkait dengan topik aktivitas otak berbahaya, *electroencephalography* (EEG),

spektrogram, *deep learning*, dan *transfer learning*. Analisis ini bertujuan untuk memperoleh pemahaman yang mendalam tentang kerangka kerja konseptual, teknologi, dan metodologi yang relevan dengan penelitian ini. Hasil dari tahap ini dituangkan BAB II Landasan Teori dan *Related Works*.

3.3.2 *Data Acquisition*

Dataset yang dipakai bersumber dari *Kaggle Competition Harmful Brain Activity* yang diadakan oleh *Harvard Medical School* untuk keperluan penelitian (www.kaggle.com/competitions/hms-harmful-brain-activity-classification).

Dataset ini terdiri dari data EEG yang dikumpulkan dari 1950 pasien yang mengalami kondisi kritis, termasuk *seizure* dan jenis aktivitas otak lainnya yang berpotensi berbahaya seperti *discharges periodik lateralized* (LPD), *generalized periodic discharges* (GPD), *lateralized rhythmic delta activity* (LRDA), *generalized rhythmic delta activity* (GRDA) dan *others*. Pola-pola abnormal yang dikategorikan sebagai ‘*others*’ ini meliputi puncak *epileptiform sporadis* seperti *spike*, gelombang tajam, dan *polyspikes*, bersama dengan perlambatan fokal atau umum yang ditandai dengan penurunan laju periodisitas gelombang. Pola *Burst Suppression*, yang ditandai dengan rangkaian ulang aktivitas yang memudar, juga termasuk, begitu pula dengan latar belakang tegangan rendah atau yang tereduksi, menandakan penurunan intensitas gelombang. File yang digunakan sebagai *training dataset* maupun *validation* terdiri dari:

a. *Train.csv*

File *train.csv* ini berisi metadata dari data pelatihan, yang terdiri dari rekaman EEG berdurasi 50 detik dengan spektrogram mencakup *window* 10 menit

yang berpusat di tengah pada waktu yang sama dan memberi label pada 10 detik tengah oleh annotator ahli (Jin Jing et al., 2024). Pada file *train.csv* ini terdapat 106.800 baris yang merepresentasikan subsampel EEG yang telah diberi label atau metadata yang digunakan untuk mengidentifikasi *subsample* EEG.

Metadata tersebut mencakup kolom seperti *eeg_id* untuk identifikasi unik dari seluruh rekaman EEG, *eeg_sub_id* untuk menandai subsampel spesifik dengan durasi 50 detik yang diberi label, *eeg_label_offset_seconds* yang menunjukkan jarak waktu antara awal rekaman EEG yang disatukan dan *subsample* yang bersangkutan, serta kolom lainnya seperti *spectrogram_id*, *spectrogram_sub_id*, dan *label_id* untuk tujuan identifikasi. Informasi tentang konsensus annotator juga tersedia dalam kolom *expert_consensus*. Selain itu, terdapat kolom target yang mencatat jumlah *vote* dari masing-masing kelas aktivitas otak seperti *seizure*, *lpd*, *gpd*, *lrda*, *grda*, dan *other*.

b. Folder *train EEGs*

Dalam *folder train EEGs* berisi 17300 data sampel sinyal EEG dengan format *parquet*. Setiap file terdapat 12.000 baris dan 20 kolom, yang setiap kolomnya mewakili nilai dari beberapa elektroda yang ditempatkan pada lokasi tertentu. Sedangkan pada baris mewakili nilai dari elektroda dari waktu ke waktu.

c. Folder *train Spectrograms*

Folder *train spectrograms* berisi 11138 data dengan format *parquet* yang terdiri dari serangkaian frekuensi dari waktu dalam hertz dan wilayah perekaman elektroda EEG yaitu *Left Lateral* (LL), *Right Lateral* (RL), *Left Parasagittal* (LP) dan *Right Parasagittal* (RP).

3.3.3 Data Preprocessing

Data preprocessing dilakukan untuk mempersiapkan *dataset* sebelum analisis lebih lanjut. Langkah-langkah yang diambil yaitu seperti *data cleaning* untuk menghilangkan duplikasi, input *missing values*, *transformation* untuk mengubah format data menjadi lebih sesuai, dan *augmentation* untuk meningkatkan jumlah dan variasi data. Teknik augmentasi yang digunakan termasuk *MixUp* dan *RandomCutout* untuk *frequency and time masking*.

- a. Augmentasi *MixUp* adalah teknik yang menggabungkan dua sampel data menjadi satu dengan cara mengambil rata-rata bobot kelas dan label dari kedua sampel tersebut. Hal ini dapat membantu model untuk belajar dari variasi data yang lebih besar dan mengurangi *overfitting*.
- b. Augmentasi *Random Cutout* adalah teknik yang menghapus sebagian informasi dari sampel data dengan cara acak pada domain frekuensi dan waktu. Dengan demikian, teknik ini dapat membantu model untuk belajar dengan lebih baik dalam menghadapi data yang tidak lengkap atau terdistorsi.

Dalam penelitian ini, augmentasi data diterapkan menggunakan teknik dan parameter yang ditampilkan pada tabel 3.1.

Tabel 3. 1 Teknik Augmentasi

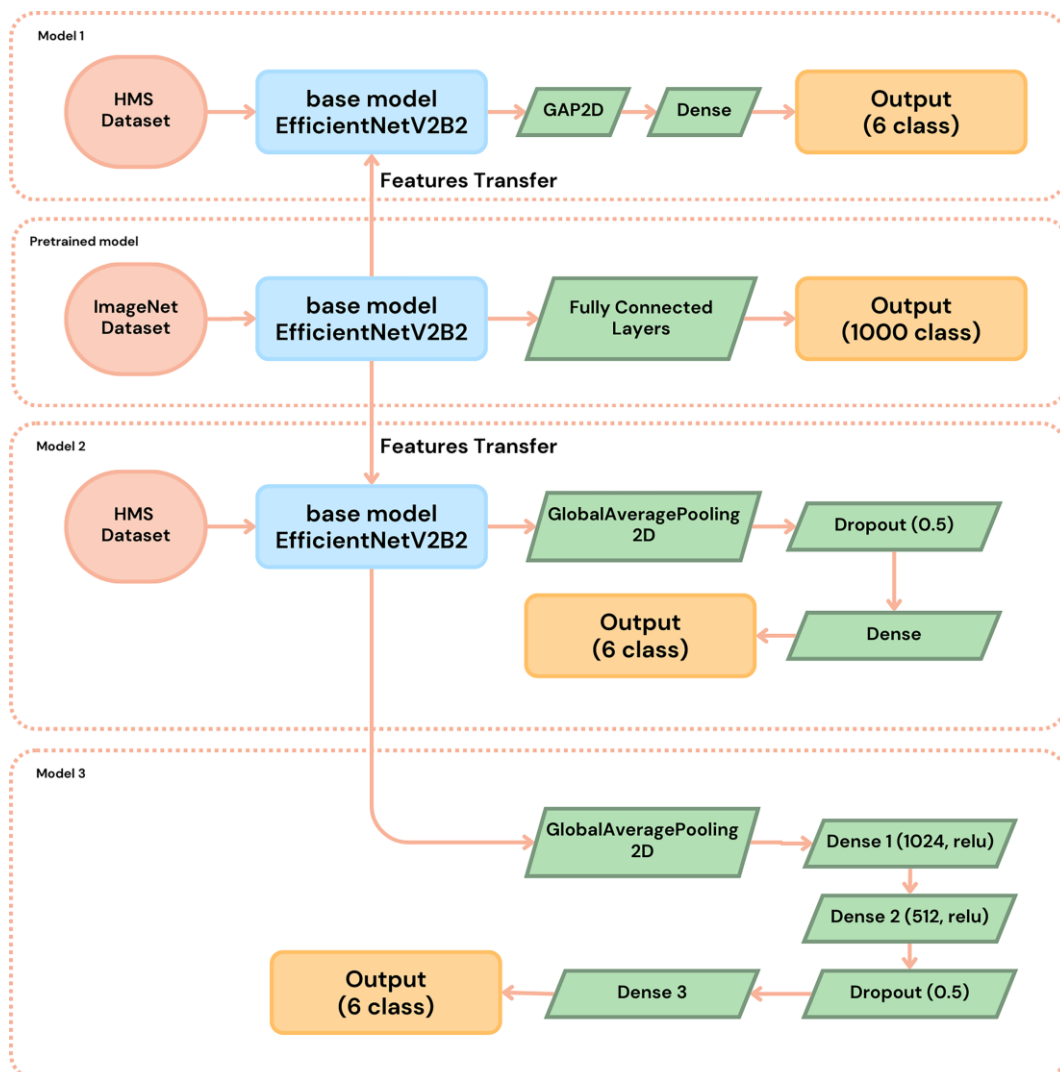
Teknik Augmentasi	Parameter
<i>RandomCutout</i>	<i>height_factor</i> =(0.5, 0.8), <i>width_factor</i> =(0.2, 0.4)
<i>RandomCutout</i>	<i>height_factor</i> =(0.2, 0.4), <i>width_factor</i> =(0.2, 0.4)
<i>RandomFlip</i>	N/A
<i>MixUp</i>	<i>alpha</i> =2.0

Tujuan dari *pre-processing* ini adalah untuk meningkatkan kualitas dan konsistensi *dataset*, sehingga model yang dikembangkan dapat bekerja dengan lebih efektif dan menghasilkan hasil yang lebih akurat.

3.3.4 Modeling

Pada tahap *modelling*, dilakukan konfigurasi model *convolutional network* dengan menerapkan pendekatan *Transfer Learning pre-trained model EfficientNetV2*. Langkah ini melibatkan penyesuaian *hyperparameter* dan *fine-tuning* model untuk memperoleh kinerja yang optimal. *EfficientNetV2* dipilih sebagai arsitektur model karena kemampuannya dalam menangani data gambar dengan efisien dan efektif. Proses *fine-tuning* dilakukan untuk menyesuaikan model *pre-trained* dengan *dataset* baru, sehingga model dapat belajar pola-pola yang relevan dari data EEG yang digunakan dalam penelitian.

Terdapat tiga model utama yang digunakan dalam penelitian ini, Gambar 3.4 merupakan arsitektur beberapa model yang digunakan dalam penelitian.



Gambar 3. 4 Arsitektur Model

Ketiga model ini memanfaatkan *pretrained model EfficientNetV2B2* yang telah dilatih sebelumnya pada *dataset ImageNet*. Model pertama (Model 1) menggunakan *dataset* dari *Harvard Medical School* (HMS) dan memanfaatkan arsitektur *EfficientNetV2B2* yang sudah di *pretrained* pada *dataset ImageNet*. Proses ekstraksi fitur dilakukan melalui *GlobalAveragePooling2D* (GAP2D) yang kemudian dihubungkan dengan lapisan *Dense* untuk menghasilkan output akhir yang mengklasifikasikan gambar ke dalam enam kelas. Model kedua (Model 2)

juga menggunakan *dataset* HMS dan *pretrained model* *EfficientNetV2B2* dengan bobot *ImageNet* lalu melakukan ekstraksi fitur dengan GAP2D, namun dilanjutkan dengan penambahan lapisan *Dropout* untuk mencegah *overfitting* sebelum menghasilkan *output* akhir dengan 6 kelas. Model ketiga (Model 3) merupakan pengembangan dari Model 2. Selain menggunakan GAP2D untuk ekstraksi fitur dan menambahkan lapisan *Dropout*, model ini juga menambahkan dua lapisan *Dense* dengan aktivasi *Rectified Linear Unit* (ReLU) (pada *Dense* 1 dan *Dense* 2) di antara GAP2D dan *Dropout*. Penambahan ini bertujuan untuk meningkatkan kemampuan model dalam menangkap pola-pola yang lebih kompleks sebelum menghasilkan *output* akhir yang mengklasifikasikan gambar ke dalam enam kelas.

3.3.5 *Training & Validation*

Pada tahap pelatihan (*training*) dan validasi (*validation*) ini, model yang telah dibangun diinstruksikan untuk mempelajari pola-pola yang ada dalam *dataset* yang telah diproses sebelumnya, di mana model akan diperbarui secara iteratif melalui serangkaian *epoch* untuk mengoptimalkan kinerjanya dalam mengklasifikasikan aktivitas otak berbahaya. Selama pelatihan, dilakukan juga validasi menggunakan subset data yang berbeda, yang bertujuan untuk mengukur kinerja model pada data yang tidak digunakan dalam proses pelatihan dan memastikan bahwa model mampu melakukan generalisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

Penelitian ini menguji empat skenario dengan konfigurasi berbeda untuk mengevaluasi kinerja model yang telah dikembangkan. Tabel 3.2 merupakan rincian dari setiap skenario pengujian. Setiap skenario menggunakan model yang

berbeda dan menguji pengaruh augmentasi data serta penambahan lapisan atau *layer* pada model terhadap performa model.

Tabel 3. 2 Skenario Pengujian

Skenario Pengujian	Model	Augmentasi	Epoch	Optimizer	Batch Size	Initial LR	GPU
1	Model 1	×	50	Adam	64	1e-4	T4 x2
2	Model 1	✓	50	Adam	64	1e-4	T4 x2
3	Model 2	✓	50	Adam	64	1e-4	T4 x2
4	Model 3	✓	50	Adam	64	1e-4	T4 x2

Skenario 1 menggunakan model awal (Model 1) tanpa penambahan apapun dan tanpa augmentasi data. Dalam skenario ini, model diuji dalam kondisi paling dasar untuk melihat performa dasar dari model yang belum dikembangkan. Skenario 2 tetap menggunakan arsitektur model yang sama seperti skenario 1 (Model 1), tetapi menerapkan augmentasi data untuk melihat apakah augmentasi data dapat meningkatkan kinerja model dasar. Skenario 3 menggunakan Model 2, yang merupakan pengembangan arsitektur dari Model 1 dengan penambahan lapisan *dropout*, dan menerapkan augmentasi untuk melihat peningkatan potensi dalam generalisasi model. Skenario 4 menggunakan Model 3, yang lebih kompleks dengan penambahan dua lapisan *dense* dan lapisan *dropout*. Seperti pada skenario sebelumnya, augmentasi data juga diterapkan. Skenario ini dirancang untuk melihat dampak dari arsitektur yang lebih dalam dan kompleks serta augmentasi data pada performa model. Semua skenario menggunakan *optimizer Adam* dengan *learning rate* awal yang sama, yaitu 1e-4, *batch size* 64 dan dijalankan selama 50 *epoch* menggunakan GPU T4 x2.

3.3.6 *Evaluation*

Pada tahap evaluasi, penilaian dan perbandingan dilakukan terhadap kinerja model klasifikasi aktivitas otak berbahaya yang dikembangkan dengan model *pre-trained* lainnya. Proses evaluasi menggunakan metrik *accuracy* dari *Keras API* dengan persamaan (2.1) untuk mengukur efektivitas serta akurasi prediksi model.

3.3.7 **Penarikan Kesimpulan**

Setelah melakukan evaluasi terhadap kinerja model dalam mengklasifikasikan aktivitas otak berbahaya, tahap selanjutnya adalah penarikan kesimpulan. Langkah ini penting dalam menentukan efektivitas dan keandalan model dalam mengidentifikasi. Kesimpulan yang diambil dari tahap ini akan memberikan informasi tentang kinerja model dan memberikan saran perbaikan untuk penelitian selanjutnya.