

BAB I

PENDAHULUAN

1.1 Latar Belakang

Aktivitas otak berbahaya mengacu pada pola aktivitas listrik tidak normal di otak yang dapat menimbulkan efek merugikan pada fungsi kognitif dan fisik seseorang. Salah satu bentuk aktivitas otak berbahaya yang terkenal adalah *seizure* atau kejang, yang ditandai dengan aktivitas listrik abnormal di otak yang dapat menyebabkan berbagai gejala, mulai dari kejang-kejang hingga kehilangan kesadaran dan gerakan yang tidak disengaja (Rodriguez Ruiz et al., 2017). Selain *seizure*, ada pola lain dari aktivitas otak berbahaya yang mirip dengan *seizure* seperti *Generalized Periodic Discharges* (GPD), *Lateralized Periodic Discharges* (LPD), *Lateralized Rhythmic Delta Activity* (LRDA), *Generalized Rhythmic Delta Activity* (GRDA). Pola-pola ini memiliki potensi untuk merusak otak dan dapat meningkatkan risiko kematian jika terlambat terdeteksi dan dibiarkan berlanjut dalam jangka waktu yang lama. Oleh karena itu, deteksi dan klasifikasi *seizure* dan pola abnormal lainnya yang mirip dengan *seizure* secara otomatis dan akurat menjadi sangat diperlukan untuk pengobatan dan perawatan yang tepat, terutama pada pasien yang sakit kritis. Namun, saat ini deteksi otomatis untuk pola-pola ini masih terbatas (Ge et al., 2021).

Pemantauan dan deteksi aktivitas listrik otak, termasuk pola seperti *seizure* dan pola lain dari aktivitas otak berbahaya yang mirip *seizure*, dapat dilakukan menggunakan alat yang disebut *Electroencephalography* (EEG). Teknik EEG digunakan dalam lingkungan klinis sebagai alat pengukuran dan pendeteksian pola

aktivitas otak dengan merekam sinyal listrik yang dihasilkan otak (Biasiucci et al., 2019). Untuk membaca hasil dari tangkapan frekuensi gelombang otak EEG dan mengklasifikasi aktivitas otak berbahaya, para peneliti menggunakan spektrogram sebagai representasi visual dari spektrum frekuensi sinyal yang membentuk pola berbeda-beda dari waktu ke waktu (Eker et al., 2022). Pada penelitian ini spektrogram digunakan sebagai input untuk melatih model *deep learning* untuk mengklasifikasikan pola sinyal dari EEG.

Masalah utama dalam bidang ilmu saraf (*neuroscience*) adalah terbatasnya kumpulan *dataset* yang besar untuk melatih dan mengevaluasi algoritma, yang seringkali berdampak pada kurangnya akurasi, terutama dalam konteks otomatisasi deteksi *seizure* dan pola-pola aktivitas otak berbahaya lainnya yang menyerupai *seizure* (Jing et al., 2023). Untuk mengatasi keterbatasan ini, beberapa penelitian telah mengadopsi berbagai pendekatan, salah satunya adalah penggunaan *deep learning* dan teknik *transfer learning*, di mana model yang telah dilatih sebelumnya pada tugas-tugas serupa digunakan untuk meningkatkan kinerja model baru (Ali et al., 2023). Pendekatan ini tidak hanya memungkinkan penghematan waktu dan sumber daya, tetapi juga dapat meningkatkan kemampuan model untuk menggeneralisasi data baru dan mengatasi keterbatasan *dataset* yang ada.

Penelitian yang dilakukan oleh (B. Zhang et al., 2020) membahas penggunaan model VGG16, VGG19 dan *ResNet* berbasis CNN dan *transfer learning* dalam meningkatkan deteksi *seizure* dan menghasilkan akurasi tertinggi 96.17% dengan *ResNet*. Namun, penelitian ini juga menyarankan untuk

mengeksplorasi penggunaan model *deep learning* lainnya dan teknik *transfer learning* guna meningkatkan akurasi deteksi *seizure*.

EfficientNetV2 merupakan salah satu *pre-trained* model yang populer untuk *transfer learning* karena kemampuannya dalam mentransfer pengetahuan secara efektif dari satu domain ke domain lainnya, terutama dalam scenario data yang terbatas. Penelitian (Tan & Le, 2021) menunjukkan bahwa *EfficientNetV2* ini mengungguli model sebelumnya dalam *image recognition* dan *transfer learning*. Pada penelitiannya model ini lebih efisien secara parameter, dapat melatih dengan kecepatan hingga 11 kali lebih cepat, dan memiliki ukuran yang lebih kecil hingga 6,8 kali lipat daripada *ConvNets* dan *Transformers*, mengungguli model-model terbaru seperti *RegNet* dan *Vision Transformers* dengan *dataset* CIFAR-10, CIFAR-100, *Flowers* dan *Cars*. Pada penelitian (Ittisoponpisan et al., 2022) model *EfficientNetV2* menunjukkan kecepatan inferensi dan akurasi yang lebih baik, dengan *FLOPs* sebesar 0,71G, waktu inferensi pada *CPU* adalah 1097 ms, pada *GPU* 91 ms, dan akurasi mencapai 90,99%. Penelitian ini menunjukkan bahwa *EfficientNetV2* cocok untuk pelatihan dengan sumber daya komputasi terbatas dibandingkan dengan model lain seperti *MobileNetV1*, *MobileNetV2*, *MobileNetV3*, *EfficientNetV1*, *ResNet50V1*, dan *ResNet50V2* memiliki kombinasi kecepatan dan akurasi yang lebih rendah.

Penelitian-penelitian lain (Acharya et al., 2018; Emami et al., 2019; Jing et al., 2023) juga menyoroti bahwa terbatasnya penelitian tentang otomatisasi deteksi *seizure* dan pola-pola lainnya ini disebabkan oleh kurangnya kumpulan *dataset* yang besar untuk melatih dan mengevaluasi algoritma. Solusi dalam mengatasi

masalah terbatasnya *dataset* ini dapat dilakukan dengan augmentasi data (Lashgari et al., 2020; Rommel et al., 2022). Augmentasi data memungkinkan peningkatan ukuran set pelatihan dengan menambahkan contoh sintetis baru melalui transformasi acak dari contoh yang ada, dengan tetap mempertahankan labelnya (S. Chen et al., 2020).

Berdasarkan deskripsi masalah tersebut, penelitian ini akan mengembangkan model *machine learning* yang mampu secara akurat mengklasifikasikan aktivitas otak yang berbahaya dalam sinyal EEG. Teknik *transfer learning* dan beberapa teknik augmentasi yang belum digunakan dalam penelitian sebelumnya akan dikombinasikan untuk meningkatkan performa model. Kombinasi yang diusulkan dari kedua pendekatan ini diharapkan dapat meningkatkan kinerja model, menghasilkan model klasifikasi aktivitas otak berbahaya yang lebih akurat dan dapat diandalkan. Dengan demikian, penelitian ini tidak hanya memperluas bidang pengetahuan tentang pemrosesan sinyal EEG, tetapi juga memberikan kontribusi praktis dalam pengembangan sistem deteksi dini dan intervensi untuk kondisi medis yang berkaitan dengan gangguan otak.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang dijelaskan, rumusan masalah dalam penelitian ini meliputi:

1. Bagaimana merancang dan mengimplementasikan model *transfer learning* guna mencapai tingkat kinerja yang optimal dalam mengklasifikasikan aktivitas otak berbahaya?

2. Bagaimana model dapat dikembangkan untuk meningkatkan performanya dalam klasifikasi aktivitas otak berbahaya berdasarkan sinyal *electroencephalography* (EEG) dengan menerapkan teknik augmentasi?
3. Bagaimana perbandingan antara hasil evaluasi *pre-trained model* yang belum ditingkatkan dan model yang telah dikembangkan?

1.3 Tujuan Penelitian

Tujuan penelitian yang ingin dicapai adalah:

1. Merancang dan mengimplementasikan penyesuaian model *transfer learning* sehingga mencapai kinerja optimal dalam mengklasifikasikan aktivitas otak berbahaya.
2. Mengembangkan model yang dapat meningkatkan performanya dalam klasifikasi aktivitas otak berbahaya berdasarkan sinyal *electroencephalography* (EEG) dengan menerapkan teknik augmentasi.
3. Melakukan perbandingan antara hasil evaluasi *pre-trained model* yang belum ditingkatkan dan model yang telah dikembangkan untuk menunjukkan peningkatan kinerja yang diperoleh.

1.4 Manfaat Penelitian

Adapun beberapa manfaat yang diperoleh dalam penelitian ini adalah:

1. Peningkatan kinerja model dalam klasifikasi aktivitas otak berbahaya berdasarkan sinyal *electroencephalography* (EEG), yang dapat membantu dalam diagnosis dan pengelolaan kondisi kesehatan yang terkait dengan gangguan otak.

2. Penelitian ini dapat dijadikan sebagai acuan dalam studi yang berkaitan dengan kecerdasan buatan dan visi komputer, terutama dalam konteks penerapan pembelajaran mendalam untuk mengklasifikasikan aktivitas otak berbahaya berdasarkan sinyal *electroencephalography* (EEG).

1.5 Batasan Masalah

Ada beberapa batasan masalah yang perlu diperhatikan dalam penelitian ini, antara lain:

1. *Dataset* yang digunakan berasal dari *Kaggle* (Jin Jing et al., 2024) dan terdiri dari data EEG dari 1950 pasien, dengan 11138 spektrogram dan 17089 ID EEG. Semua data EEG, baik untuk pelatihan maupun pengujian, dikumpulkan pada frekuensi 200 sampel per detik.
2. *Dataset* hanya mencakup data EEG dari pasien yang menderita kondisi kritis seperti peristiwa *seizure*, *lateralized periodic discharges* (lpd), *generalized periodic discharges* (gpd), *lateralized rhythmic delta activity* (lrda), dan *generalized rhythmic delta activity* (grda), yang mungkin memiliki pola aktivitas otak yang berbeda dari pasien sehat atau non-kritis.
3. Label untuk kelas aktivitas otak didasarkan pada penilaian oleh para ahli (Jin Jing et al., 2024), yang memiliki kriteria atau interpretasi yang berbeda dari data EEG dan spektrogram.
4. Model yang dikembangkan dalam *transfer learning* adalah *EfficientNetV2*.
5. Komputasi yang dipakai pada penelitian ini menggunakan *Kaggle Notebook* dengan memori dan *gpu* yang terbatas.