

BAB II

LANDASAN TEORI

2.1 Landasan Teori

2.1.1 Aktivitas Otak Berbahaya

Aktivitas otak yang berbahaya mengacu pada pola abnormal aktivitas saraf yang dapat berdampak negatif pada kesehatan dan fungsi otak seseorang. Otak adalah organ kompleks yang bertanggung jawab untuk mengendalikan berbagai fungsi tubuh, mengatur emosi, dan memproses informasi (Carter et al., 2019). Ketika aktivitas otak berbahaya ini terjadi, maka akan mengganggu proses kerja otak dan dapat menyebabkan berbagai dampak negatif seperti gangguan pada fungsi kognitif, emosi bahkan kondisi neurologis seperti *seizure* sampai *epilepsy*.

Ada beberapa faktor yang dapat menyebabkan aktivitas otak yang berbahaya. Salah satu penyebab yang umum adalah adanya sinyal listrik yang tidak normal dalam otak. Sinyal abnormal ini dapat mengganggu fungsi normal neuron dan mengganggu transmisi informasi antara berbagai otak. Hal ini dapat menyebabkan kejang atau *seizure*, yang ditandai dengan gejala tiba-tiba dan tidak terkendali dari aktivitas listrik dalam otak (National Institute of Neurological Disorders and Stroke, 2023). *Seizure* merupakan salah satu bentuk dari aktivitas otak yang berbahaya dan dapat memiliki dampak yang signifikan terhadap kesehatan seseorang. *Seizure* ini memiliki berbagai gejala yang bervariasi tergantung pada jenis dan tingkat keparahan kejang. *Seizure* dapat disebabkan oleh berbagai faktor, termasuk epilepsi, cedera kepala, tumor otak, infeksi, dan kondisi genetik tertentu (Anwar et al., 2020).

Selain pola abnormal *seizure*, ada beberapa pola lainnya yang mirip dengan *seizure* yaitu peristiwa atau pola yang menyerupai *seizure* yang merupakan pola aktivitas listrik yang abnormal di otak dan seringkali terkait dengan kondisi yang dapat menyebabkan *seizure* atau gejala neurologis lainnya. Pola ini meliputi *Generalized Periodic Discharges* (GPD), *Lateralized Periodic Discharges* (LPD), *Lateralized Rhythmic Delta Activity* (LRDA), *Generalized Rhythmic Delta Activity* (GRDA).

a. *Generalized Periodic Discharges* (GPD)

Generalized Periodic Discharges (GPD) adalah pola aktivitas pada gelombang *electroencephalography* (EEG) yang dapat terlihat pada berbagai ensefalopati (kelompok penyakit yang mempengaruhi struktur atau fungsi otak), dengan morfologi dan durasi yang relatif seragam, serta interval antar pelepasan yang dapat diukur (Sully & Husain, 2018). Pola ini dikaitkan dengan sejumlah kondisi penyakit, termasuk anoksia, ensefalopati toksik/metabolik, infeksi, status epileptikus non-kejang, dan hipotermia (Hartshorn & Foreman, 2019; Sully & Husain, 2018). Pelepasan listrik abnormal ini dapat mengganggu fungsi otak yang normal dan menyebabkan gangguan kognitif serta gejala neurologis lainnya (H. Zhang et al., 2019).

b. *Lateralized Periodic Discharges* (LPD)

Lateralized Periodic Discharges (LPD) merupakan pola aktivitas listrik otak yang abnormal dan biasanya terkait dengan disfungsi otak akut atau subakut, seringkali berhubungan dengan lesi struktural otak atau cedera otak akut. Pola dari LPD ini banyak diamati pada berbagai gangguan neurologis akut seperti *seizure*

atau penurunan kesadaran (Fatima et al., 2022; Misulis et al., 2022). *Lateralized* pada LPD berarti pola ini terjadi di satu sisi otak dan menunjukkan pola berulang pada EEG. Jika dilihat pada data EEG, LPD muncul sebagai gelombang beraturan dengan kontur tajam yang menonjol dari aktivitas otak latar belakang dan berulang pada interval tertentu. LPD biasanya bersifat *unilateral*, mempengaruhi hemisfer kiri atau kanan otak, yang merupakan aspek penting dalam interpretasinya (Hirsch et al., 2021).

c. *Lateralized Rhythmic Delta Activity (LRDA)*

Lateralized Rhythmic Delta Activity (LRDA) adalah pola gelombang otak yang ditandai dengan gelombang lambat berirama. Gelombang ini biasanya berada dalam kisaran frekuensi delta (1-4 Hz) dan terlokalisasi pada satu sisi otak (Sinha, 2018). Ciri khas LRDA adalah sifatnya yang lateral, yang berarti hanya mempengaruhi satu sisi otak. Ciri *lateral* ini dapat membantu dokter untuk menentukan lokasi lesi atau disfungsi neurologis. Bentuk gelombang LRDA berbeda dengan LPD. LRDA memiliki bentuk gelombang yang lebih halus dan lebih berirama, sedangkan LPD memiliki bentuk gelombang yang tajam (Hirsch et al., 2021). LRDA sering diamati pada pasien dengan lesi otak fokal seperti *stroke*, tumor, atau peradangan. Hal ini juga dapat dilihat pada pasien dengan aktivitas kejang fokal (Figueiredo et al., 2021).


d. *Generalized Rhythmic Delta Activity (GRDA)*

Generalized Rhythmic Delta Activity (GRDA) adalah pola EEG yang ditandai dengan aktivitas delta berirama yang tersebar lebih merata di kedua hemisfer otak. Berbeda dengan LRDA (*Lateralised Rhythmic Delta Activity*) yang

terfokus di satu sisi, GRDA tersebar dikedua sisi otak, seringkali secara simetris (Figueiredo et al., 2021). Pola GRDA didefinisikan oleh gelombang delta berirama yang terus menerus atau semi-terus menerus. Aktivitas ini lebih lambat dan lebih berirama dibandingkan dengan GPD (*Generalized Periodic Discharges*) (Hirsch et al., 2021). GRDA dapat terlihat pada berbagai kondisi klinis, termasuk ensefalopati dengan berbagai penyebab (seperti gangguan metabolik-toksik), dan dalam beberapa kasus, selama tahap tidur tertentu atau pada gangguan otak yang luas. Kehadiran GRDA bisa menjadi indikasi disfungsi otak secara keseluruhan dan memerlukan investigasi lebih lanjut untuk mengidentifikasi penyebabnya (Sinha, 2018).

2.1.2 *Electroencephalography* (EEG)

Electroencephalography (EEG) adalah teknik *neurofisiologis non-invasif* yang digunakan untuk merekam aktivitas listrik di otak. Metode ini menggunakan elektroda yang ditempatkan pada kulit kepala untuk mendeteksi muatan listrik kecil yang dihasilkan oleh aktivitas sel-sel otak (Biasiucci et al., 2019). Sinyal yang ditangkap dan direkam oleh elektroda ini biasanya diamplifikasi dan disimpan untuk analisis oleh para spesialis. Sinyal EEG ini menggambarkan perubahan voltase dari waktu ke waktu. Pola yang diamati dalam data EEG dipengaruhi oleh aktivitas otak seseorang. Kondisi kesadaran, aktivitas, atau kondisi neurologis apa pun dapat menyebabkan pola tersebut sangat berbeda.



Gambar 2. 1 Cara kerja EEG (Nagel, 2019)

Salah satu keunggulan utama EEG adalah resolusi temporalnya yang tinggi, yang memungkinkannya mendeteksi perubahan cepat dalam aktivitas otak. Kemampuannya dalam mendeteksi perubahan cepat ini membuat EEG sangat berguna untuk mempelajari proses yang terjadi dalam skala milidetik, seperti kesadaran, aktivitas, atau kondisi neurologis lainnya (Biasiucci et al., 2019).

2.1.3 Spektogram

Spektogram adalah representasi visual dari frekuensi yang ada dalam sinyal dari waktu ke waktu dan biasa digunakan dalam bidang-bidang seperti pemrosesan audio, analisis ucapan, dan gambar. Spektrogram menampilkan intensitas frekuensi yang berbeda dalam sinyal dengan merepresentasikannya sebagai variasi warna atau skala abu-abu. Dengan menganalisis spektrogram, seseorang dapat mengidentifikasi pola, anomali, dan informasi penting lainnya tentang sinyal (Khodzhaev, 2022).

Dalam konteks analisis EEG, spektrogram dapat membantu mengidentifikasi pita frekuensi tertentu yang terkait dengan kondisi kesadaran atau proses kognitif yang berbeda. Untuk menghasilkan spektrogram dari data EEG, sinyal domain waktu pertama-tama dibagi menjadi beberapa segmen pendek, biasanya menggunakan teknik yang disebut *windowing*. Setiap segmen kemudian ditransformasikan ke dalam domain frekuensi menggunakan teknik seperti *Fast Fourier Transform* (FFT). Spektrum yang dihasilkan kemudian diplot sebagai fungsi waktu, dengan warna yang menunjukkan amplitudo atau kekuatan setiap komponen frekuensi (Eker et al., 2022)

2.1.4 *Image Classification*

Image classification atau klasifikasi gambar adalah tugas mendasar dalam *computer vision* yang melibatkan pengelompokan gambar ke dalam kelas atau kategori yang berbeda berdasarkan konten visualnya. Tujuan dari klasifikasi gambar adalah untuk mengembangkan algoritma dan model yang secara otomatis dapat mengidentifikasi dan memberikan label pada gambar, sehingga memungkinkan pengorganisasian dan pengambilan data visual yang efisien (L. Chen et al., 2021). Tugas ini memiliki banyak aplikasi di berbagai bidang, seperti pengenalan objek, pencitraan medis, pengawasan, dan banyak lagi.

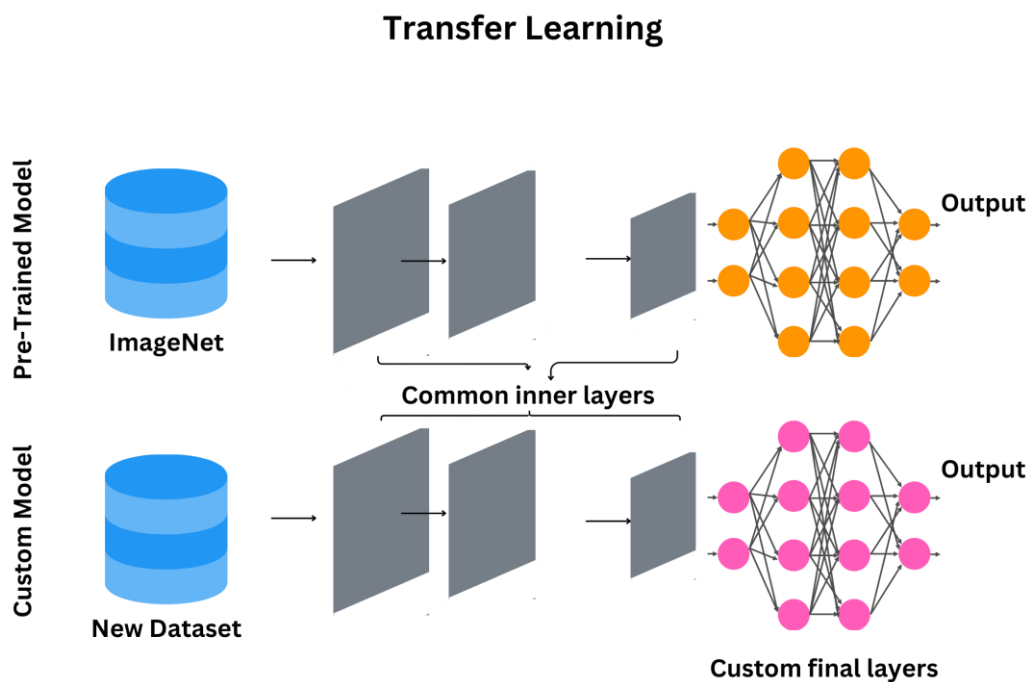
Proses klasifikasi gambar dimulai dengan mengumpulkan dan melakukan pra pemrosesan kumpulan data gambar berlabel dalam jumlah besar. Gambar-gambar ini kemudian digunakan untuk melatih model, di mana algoritma mempelajari pola dan fitur yang membedakan satu kelas dengan kelas lainnya. Setelah model dilatih, model dapat digunakan untuk mengklasifikasikan gambar

baru yang belum pernah dilihat sebelumnya dengan mengekstraksi fitur-fiturnya dan membandingkannya dengan pola yang telah dipelajari (Brownlee, 2019).

2.1.5 *Transfer Learning*

Transfer learning merupakan teknik *machine learning* yang memanfaatkan pengetahuan yang diperoleh dari suatu tugas untuk meningkatkan performa pada tugas lain yang terkait namun berbeda. *Transfer learning* dapat didefinisikan sebagai penerapan pengetahuan dari satu konteks ke konteks lainnya (Q. Yang et al., 2020). (Ali et al., 2023) menjelaskan *transfer learning* dalam konteks *machine learning* mengacu pada penerapan pengetahuan dari satu tugas untuk meningkatkan kinerja pada tugas terkait. Pendekatan *transfer learning* ini banyak dimanfaatkan ketika *dataset* yang dimiliki terbatas, karena dapat membantu mengatasi *overfitting* dan meningkatkan kinerja model. *Transfer learning* memungkinkan untuk membangun model baru yang lebih baik untuk situasi baru tanpa memerlukan pengumpulan data yang besar dan pelatihan awal dengan menggunakan kembali model yang telah dilatih sebelumnya pada *dataset* yang besar.

Penelitian (Joshi et al., 2023) menyatakan bahwa tugas-tugas *computer vision* seperti klasifikasi gambar, deteksi objek, dan pelacakan objek dapat memanfaatkan *transfer learning* dengan model *deep learning*, untuk memberikan solusi yang efektif dan efisien dalam permasalahan yang kompleks.



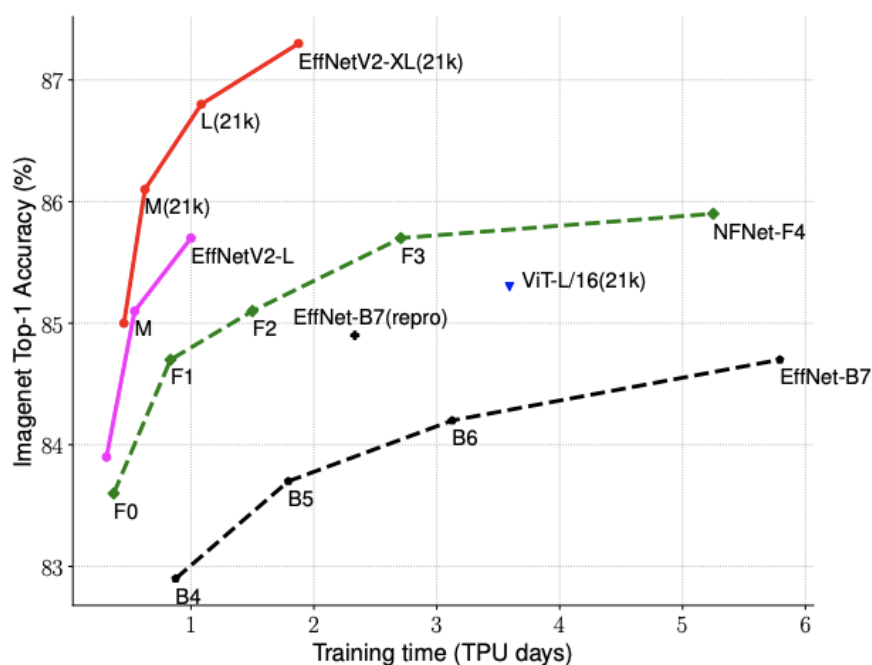
Gambar 2. 2 Cara kerja *transfer learning*

Ilustrasi pada Gambar 2.1 menjelaskan konsep *transfer learning* dalam *computer vision*. Pada *transfer learning*, model yang telah di-latih sebelumnya dengan *dataset* besar seperti *ImageNet* digunakan sebagai dasar (*base model*). Lapisan-lapisan model awal tersebut dibekukan (*freeze*), artinya bobotnya tidak diubah selama proses pelatihan berikutnya. Selanjutnya, lapisan-lapisan baru ditambahkan di atas model yang telah dilatih sebelumnya dan hanya lapisan-lapisan baru tersebut yang dilatih kembali. Model awal bertindak sebagai *extractor* fitur, mengekstrak fitur-fitur penting dari *dataset* baru, sementara lapisan-lapisan baru belajar untuk mengklasifikasikan fitur-fitur tersebut berdasarkan tugas spesifik yang diberikan (Q. Yang et al., 2020).

2.1.6 *EfficientNet*

EfficientNetV2 adalah bagian dari *convolutional neural network* yang dirancang untuk mempunyai kecepatan *training* lebih cepat dan efisiensi parameter

yang lebih baik. Pengembangan model ini melibatkan kombinasi pencarian dan penskalaan arsitektur neural yang *training-aware* atau kemampuannya dalam memperhitungkan proses *training* dan dampaknya terhadap kinerja model (Tan & Le, 2021).



Gambar 2. 3 *ImageNet ILSVRC2012 top-1 Accuracy vs. Training Time dan Parameter* (Tan & Le, 2021)

Pada penelitian (Tan & Le, 2021) menemukan ketika model *EfficientNetV2* dilatih pada *dataset ImageNet21k*, model *EfficientNetV2* menunjukkan peningkatan akurasi mencapai 87,3% akurasi top-1 pada *ImageNet ILSVRC2012*. Hasil ini mengungguli model-model terbaru seperti *Vision Transformer* (ViT) dan membutuhkan waktu pelatihan yang jauh lebih singkat, menjadikan model *EfficientNetV2* sebagai pilihan yang sangat baik untuk skenario *transfer learning* di mana efisiensi model dan kecepatan pelatihan sangat penting.

Beberapa penelitian lain juga menunjukkan keberhasilan penggunaan *EfficientNetV2* sebagai model dasar (*base model*) untuk klasifikasi gambar pada berbagai domain, seperti klasifikasi citra medis (Kurt et al., 2023), klasifikasi citra satelit (Song, 2023), dan klasifikasi objek dalam video.

2.1.7 Data Augmentasi

Data augmentasi adalah teknik untuk memperbesar *dataset* secara artifisial dengan membuat variasi baru dari data yang sudah ada. Hal ini dilakukan dengan memodifikasi data asli dengan cara-cara tertentu, seperti rotasi, pemotongan, penambahan *noise*, dan sebagainya (Haba, 2023). Tujuan utama data augmentasi adalah untuk mengatasi masalah *overfitting* dan meningkatkan *generalizability* model *machine learning*. Disamping itu pendekatan ini sangat bermanfaat ketika *dataset* asli terbatas untuk dikembangkan. Tujuan akhir dari augmentasi data adalah untuk meningkatkan kinerja model dengan menyediakan kumpulan data yang beragam (Haba, 2023).

2.1.8 Metrik Evaluasi: Akurasi

Akurasi adalah metrik yang umum digunakan dalam pembelajaran mesin dan tugas-tugas pembelajaran mendalam, terutama dalam masalah klasifikasi. Akurasi didefinisikan sebagai rasio prediksi yang benar terhadap jumlah total prediksi (Sammut & Webb, 2010). Pada *Keras*, metrik akurasi dihitung dengan menggunakan persamaan 2.1:

$$Accuracy = \frac{Total\ correct\ predictions}{Total\ predictions} \quad (2.1)$$

Dimana, *Total Correct Predictions* adalah jumlah kelas di mana prediksi model sesuai dengan label yang sebenarnya. Sedangkan *Total Predictions* adalah total jumlah kelas yang telah diprediksi oleh model.

Akurasi diekspresikan dalam rentang antara 0,0 dan 1,0, namun sering kali juga disajikan sebagai persentase. Untuk mengukur akurasi suatu model, biasanya model tersebut dievaluasi dengan menerapkannya pada data uji yang labelnya telah diketahui. Dalam hal ini, akurasi pengklasifikasi dapat dihitung dengan membagi jumlah objek yang diklasifikasikan dengan benar dengan jumlah total objek (Sammut & Webb, 2010).

2.2 Penelitian Terkait

2.2.1 *State of The Art*

Terdapat beberapa penelitian terdahulu yang dilakukan dalam topik klasifikasi berdasarkan sinyal EEG menggunakan *deep learning* maupun *transfer learning*. Namun, setiap penelitian menggunakan metode yang unik dan memberikan hasil yang berbeda-beda. Berikut ini penelitian yang terkait dengan penelitian yang dilakukan disajikan pada Tabel 2.1.

Tabel 2. 1 *State of Art*

No	Peneliti	Judul	Objek Penelitian	Algoritma	Hasil Penelitian
1.	(Doma & Pirouz, 2020)	<i>A comparative analysis of machine learning methods for emotion recognition using EEG and peripheral physiological signals</i>	Perbandingan performa <i>machine learning</i> yang berbeda untuk pengenalan emosi menggunakan EEG dan sinyal fisiologis periferal	SVM, LR, <i>Decission Trees</i> , KNN, LDA	Penelitian ini menemukan bahwa metode PCA dengan SVM memberikan hasil terbaik dalam mengklasifikasikan emosi manusia berdasarkan data EEG, dengan <i>F1-score</i> sebesar 84,73% dan recall sebesar 98,01% pada interval segmentasi 30-45 detik.
2.	(C.-Y. Yang et al., 2023)	<i>Cross-Domain Transfer of EEG to EEG or ECG Learning for CNN Classification Models</i>	Eksplorasi efektivitas <i>transfer learning</i> dalam analisis sinyal EEG dan ECG untuk tugas-tugas seperti <i>sleep-stagging</i> dan prediksi kejang.	CNN	Hasil penelitian menunjukkan bahwa <i>transfer learning</i> meningkatkan kinerja model untuk kedua tugas (<i>patient-specific transfer learning</i> dan <i>cross-signal transfer learning</i>), dengan prediksi kejang yang dipersonalisasi mencapai akurasi 100% untuk beberapa subjek dan <i>sleep staging</i> berbasis ECG mencapai akurasi 88,64% dengan <i>transfer learning</i> .
3.	(Shoeibi et al., 2021)	<i>Automatic Diagnosis of Schizophrenia in EEG Signals Using CNN-LSTM Models</i>	Eksplorasi penggunaan sinyal EEG, data fMRI, dan teknik <i>deep learning</i> untuk deteksi dan klasifikasi skizofrenia dan gangguan mental lainnya.	CNN-LSTM	Penelitian ini mengusulkan metode <i>deep learning</i> untuk diagnosis skizofrenia otomatis menggunakan sinyal EEG, dan berhasil mencapai akurasi 99,25% dengan model CNN-LSTM, yang mengungguli metode

No	Peneliti	Judul	Objek Penelitian	Algoritma	Hasil Penelitian
					<i>machine learning</i> konvensional seperti SVM, KNN, DT, Naïve Bayes, RF, ERT, bagging
4.	(Sarvi Zargar et al., 2023)	<i>Generalizable Epileptic Seizures Prediction Based On Deep Transfer Learning</i>	Mengembangkan dan menguji model <i>deep learning</i> untuk memprediksi epilepsi menggunakan data EEG, dengan fokus pada pendekatan yang bergantung pada pasien dan pendekatan yang tidak bergantung pada pasien.	<i>Exception, EfficientNet, MobileNet-V2</i>	Hasil penelitian menunjukkan bahwa penggunaan <i>deep learning</i> dengan pendekatan <i>transfer learning</i> dapat digunakan untuk memprediksi kejang epilepsi dengan tingkat sensitivitas yang tinggi. model <i>Xception convolutional network</i> dengan pengklasifikasi <i>Fully Connected</i> (FC) mencapai sensitivitas rata-rata sebesar 98,47% dalam memprediksi kejang. Sementara itu, model <i>MobileNet-V2</i> yang dilatih menggunakan data dari satu pasien dan diuji pada data enam pasien lainnya menunjukkan tingkat sensitivitas sebesar 98,39% dan FPR 0,029 per jam untuk skema <i>Pre-ictal</i> selama 40 menit.
5.	(Jana et al., 2019)	<i>Epileptic Seizure Prediction from EEG Signals Using DenseNet</i>	Mengembangkan dan evaluasi metode prediksi serangan epilepsi pada <i>patient-specific</i> menggunakan <i>DenseNet</i> untuk pembelajaran fitur dan klasifikasi.	<i>DenseNet</i>	Hasil dari penelitian ini adalah pengembangan metode prediksi serangan epilepsi khusus pasien menggunakan <i>DenseNet</i> untuk pembelajaran fitur dan klasifikasi. Metode ini mencapai akurasi klasifikasi rata-rata hingga 94% dan

No	Peneliti	Judul	Objek Penelitian	Algoritma	Hasil Penelitian
					menggunakan keputusan gabungan (<i>second pooled decision</i>) selama 30 detik untuk memprediksi kondisi pasien saat ini.
6.	(Ouichka et al., 2022)	<i>Deep Learning Models for Predicting Epileptic Seizures Using iEEG Signals</i>	Prediksi serangan epilepsi menggunakan metode <i>deep learning</i> , secara khusus berfokus pada klasifikasi <i>pre-ictal</i> dan <i>inter-ictal</i> menggunakan model CNN dan <i>transfer learning</i> dengan ResNet50.	CNN, ResNet50	Hasil penelitian menunjukkan model dengan 3-CNN dan 4-CNN mempunyai hasil akurasi tertinggi yaitu 95% dan akurasi yang dicapai dengan transfer learning ResNet50 hanya sampai 51%.
7.	(Raghu et al., 2020)	<i>EEG based multi-class seizure type classification using convolutional neural network and transfer learning</i>	Penelitian ini berfokus pada penggunaan <i>Convolutional Neural Networks</i> (CNN) untuk klasifikasi jenis <i>multi-class seizure</i> dengan data EEG.	Alexnet, Vgg16, Vgg19, Squeezenet, Googlenet, Inceptionv3, Densenet201, Resnet18, Resnet50, dan Resnet101	Hasil penelitian menunjukkan bahwa pendekatan <i>extracting image features</i> menggunakan <i>pre-trained model</i> lebih unggul daripada <i>transfer learning</i> , dengan mencapai akurasi klasifikasi sebesar 88,30% menggunakan model Inceptionv3 sedangkan dengan <i>transfer learning Googlenet</i> hanya 82,85%. Penelitian ini juga menguji coba berbagai <i>Learning Rate</i> (LR), dan menemukan bahwa LR sebesar $1e-4$ memberikan kinerja yang paling optimal. Selain itu, penelitian ini mengungkapkan bahwa lapisan ReLU dan Conv sangat penting dalam

No	Peneliti	Judul	Objek Penelitian	Algoritma	Hasil Penelitian
					mencapai akurasi klasifikasi yang tinggi."
8.	(Acharya et al., 2018)	<i>Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals</i>	Penelitian ini berfokus pada pengembangan sistem diagnosis berbantuan komputer (CAD) yang menggunakan <i>convolutional neural network</i> (CNN) untuk secara otomatis mengklasifikasikan sinyal EEG ke dalam kelas normal, preictal, dan <i>seizure</i> .	CNN	Penelitian ini menggunakan 13 layer CNN untuk mendeteksi dan klasifikasi kelas normal, preictal dan <i>seizure</i> dan akurasi yang dicapai adalah 88,67%, spesifisitas 90% dan sensisitivitas 95%
9.	(Emami et al., 2019)	<i>Seizure detection by convolutional neural network-based analysis of scalp electroencephalography plot images</i>	Deteksi <i>seizure</i> menggunakan <i>convolutional neural network</i> (CNN) untuk menganalisis gambar plot <i>electroencephalography</i> (EEG). Penelitian ini mengeksplorasi potensi CNN untuk mengenali dan mengklasifikasikan gambar plot EEG secara visual sebagai ' <i>seizure</i> ' atau ' <i>non-seizure</i> '	CNN	Dalam studi ini, CNN digunakan untuk mengklasifikasikan segmen EEG sebagai <i>seizure</i> atau <i>non-seizure</i> . Model CNN yang dibangun mendapat hasil <i>true positive</i> dalam pelabelan per detik 74%, yang lebih tinggi daripada software deteksi <i>seizure</i> komersial (20% oleh BESA dan 31% oleh Persyst).

No	Peneliti	Judul	Objek Penelitian	Algoritma	Hasil Penelitian
10.	(Truong et al., 2018)	<i>Convolutional neural networks for seizure prediction using intracranial and scalp electroencephalogram</i>	Pengembangan metode prediksi <i>seizure</i> retrospektif umum dan spesifik pasien menggunakan <i>convolutional neural network</i> (CNN) pada <i>dataset electroencephalography</i> (EEG). Metode ini bertujuan untuk mengklasifikasikan segmen <i>preictal</i> (sebelum kejang) dan <i>interictal</i> (di antara kejang) tanpa memerlukan ekstraksi fitur manual.	CNN	Penelitian ini mengusulkan metode prediksi <i>seizure</i> menggunakan transformasi fourier jangka pendek pada jendela (<i>window</i>) EEG 30 detik. Hasil kinerja dari metode yang diusulkan mencapai sensitivitas 81.4%, 81.2%, dan 75% dengan tingkat false prediction yang rendah pada tiga <i>dataset</i> yang berbeda, yaitu e of 0.06/h pada Freiburg Hospital <i>intracranial EEG dataset</i> , 0.16/h pada Boston Children's Hospital-MIT <i>scalp EEG dataset</i> , dan 0.21/h pada American Epilepsy Society <i>Seizure Prediction Challenge dataset</i> .
11.	(Muhammad Usman et al., 2020)	<i>Epileptic Seizures Prediction Using Deep Learning Techniques</i>	Penelitian ini berfokus pada pengembangan sistem yang dapat memprediksi kejang dengan menganalisis sinyal EEG dengan bantuan <i>convolutional neural networks</i> (CNN) dan <i>support vector machines</i> (SVM) sebagai <i>classifier</i> .	SVM	Hasil penelitian dari metode yang diusulkan berhasil mencapai sensitivitas rata-rata 92.7% dan spesifisitas 90.8% dalam mendeteksi keadaan preiktal pada <i>dataset</i> EEG CHBMIT dengan menggunakan bantuan CNN dan SVM sebagai <i>classifier</i> .

No	Peneliti	Judul	Objek Penelitian	Algoritma	Hasil Penelitian
			Penelitian ini menggunakan <i>dataset</i> EEG CHB-MIT, yang melibatkan 24 subjek, untuk memvalidasi keefektifan sistem prediksi kejang yang diusulkan.		
12.	(Daoud & Bayoumi, 2019)	<i>Efficient Epileptic Seizure Prediction Based on Deep Learning</i>	Mengembangkan teknik prediksi <i>seizure</i> spesifik-pasien berbasis <i>deep learning</i> dari rekaman EEG jangka panjang dan meningkatkan akurasi klasifikasi.	MLP (<i>Multi-Layer Perceptron</i>), DCNN (<i>Deep Convolutional Neural Network</i>), Bi-LSTM (<i>Bidirectional Long Short-Term Memory</i>), DCAE (<i>Deep Convolutional Autoencoder</i>)	Hasil penelitian ini mencapai akurasi tertinggi sebesar 99,6% dan tingkat <i>false alarm</i> terendah sebesar $0,004 \text{ h}^{-1}$ serta waktu prediksi kejang yang sangat dini selama satu jam dengan model DCNN + Bi-LSTM, DCAE + Bi-LSTM dan DCAE + Bi-LSTM + CS.
13.	(Ryu & Joe, 2021)	<i>A Hybrid DenseNet-LSTM Model for Epileptic Seizure Prediction</i>	Pengembangan model <i>Hybrid DenseNet-LSTM</i> untuk prediksi serangan epilepsi.	<i>DenseNet-LSTM</i>	Hasil penelitian ini adalah model <i>hybrid deep learning</i> yang menggunakan data EEG untuk memprediksi serangan epilepsi dengan menggabungkan <i>DenseNet</i> dan

No	Peneliti	Judul	Objek Penelitian	Algoritma	Hasil Penelitian
					LSTM. Untuk durasi prediksi selama lima menit, model ini menunjukkan akurasi prediksi yang tinggi yaitu 93,28%, sensitivitas 92,92%, spesifisitas 93,65%, tingkat <i>false positive</i> 0,063 per jam, dan skor F1 0,923.
14.	(Liang et al., 2020)	<i>Scalp EEG epileptogenic zone recognition and localization based on long-term recurrent convolutional network</i>	Meningkatkan akurasi deteksi <i>seizure</i> pada EEG dengan memanfaatkan teknik <i>deep learning</i> dengan model LRCN.	<i>Long-Term Recurrent Convolutional Network (LRCN)</i>	Penelitian ini diuji pada 23 pasien yang mengalami 198 kejang secara total. Hasil performa pengklasifikasi mencapai spesifisitas 99%, akurasi 99%, dan sensitivitas 84%.
15	(Nogay & Adeli, 2020)	<i>Detection of Epileptic Seizure Using Pretrained Deep Convolutional Neural Network and Transfer Learning</i>	Membangun model untuk deteksi dan klasifikasi kejang epilepsi dari sinyal EEG dengan menggunakan <i>pre-trained CNN (AlexNet)</i> .	AlexNet CNN	Model dengan <i>AlexNet</i> mencapai akurasi 100% dalam klasifikasi biner dan terner untuk deteksi kejang epilepsi.

2.2.2 Matriks Penelitian

Tabel 2. 2 Matriks Penelitian

No	Penulis	Ruang Lingkup						
		Transfer Learning	Augmentasi	Algoritma				
				Resnet	MobileNet	DenseNet	EfficientNetV2	Model Lainnya
1.	(Craik et al., 2019)	✓	-	-	-	-	-	✓
2.	(C.-Y. Yang et al., 2023)	✓	-	-	-	-	-	✓
3.	(Shoeibi et al., 2021)	-	-	-	-	-	-	✓
4.	(Sarvi Zargar et al., 2023)	✓	-	-	✓	-	✓	✓
5.	(Jana et al., 2019)	✓	-	-	-	✓	-	-
6.	(Ouichka et al., 2022)	✓	-	✓	-	-	-	✓
7.	(Raghu et al., 2020)	✓	-	✓	-	✓	-	✓
8.	(Acharya et al., 2018)	-	-	-	-	-	-	✓
9.	(Emami et al., 2019)	-	-	-	-	-	-	✓
10.	(Truong et al., 2018)	-	✓	-	-	-	-	✓
11.	(Muhammad Usman et al., 2020)	-	-	-	-	-	-	✓
12.	(Daoud & Bayoumi, 2019)	✓	-	-	-	-	-	✓
13.	(Ryu & Joe, 2021)	-	-	-	-	✓	-	✓
14.	(Liang et al., 2020)	-	-	-	-	-	-	✓
15.	(Nogay & Adeli, 2020)	✓	✓	-	-	-	-	✓
16.	Penelitian yang diusulkan	✓	✓	-	-	-	✓	-

Tabel 2.2 merupakan matriks penelitian yang berfokus pada penggunaan EEG dan *transfer learning* untuk mengatasi masalah klasifikasi aktivitas otak berbahaya. Matriks ini digunakan untuk memberikan rincian mengenai perbedaan antara penelitian yang akan dilakukan dan penelitian sebelumnya.

Berdasarkan matriks penelitian pada Tabel 2.2, penelitian ini akan melakukan klasifikasi aktivitas otak berbahaya dengan menggunakan model *deep learning* yang dikembangkan melalui teknik *transfer learning* dan menerapkan teknik augmentasi. Perbedaan antara penelitian yang akan dilakukan dengan penelitian sebelumnya, yaitu terletak pada model yang akan dikembangkan adalah *pre-trained model EfficientNet*. Selain itu penerapan beberapa augmentasi pada *dataset* juga dilakukan. Penelitian ini akan berfokus pada pengembangan model dengan teknik *transfer learning* untuk klasifikasi aktivitas otak berbahaya pada *dataset* yang berisi sinyal *electroencephalography* (EEG) yang direkam dari pasien rumah sakit yang sakit kritis.