

Analisis Kecanduan Pornography Berdasarkan Signal Electroencephalogram Menggunakan Algoritma Deep Learning

William Owen Wijaya^{1,*}, Fernando¹, Dhanny Rukmana Manday¹, Allwin M. Simarmata¹, Adli Abdillah Nababan²

¹Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Prima Indonesia, Medan, Indonesia

²Information Systems Department, School of Information Systems, Bina Nusantara University, Jakarta, Indonesia

Email: ^{1,*}williamowenwijaya191204@gmail.com, ²fernandozhuo124@gmail.com, ³dhannyrukmanamanday@unpri.ac.id,

⁴allwinsimarmata@unpri.ac.id, ⁵adli.nababan@binus.edu

Email Penulis Korespondensi: williamowenwijaya191204@gmail.com*

Submitted: 31/10/2025; Accepted: 26/11/2025; Published: 31/12/2025

Abstrak– Deteksi objektif kecanduan pornografi masih menjadi tantangan signifikan, seringkali menghambat intervensi klinis yang efektif. Penelitian ini bertujuan mengembangkan model klasifikasi Deep Learning untuk mendeteksi kecanduan pornografi secara non-invasif berdasarkan sinyal Electroencephalography (EEG). Penelitian ini menerapkan arsitektur Gated Recurrent Unit (GRU) untuk menganalisis data EEG yang diperoleh dari 14 responden menggunakan 19 channel. Data mentah diproses melalui tahapan filtering, *Independent Component Analysis* (ICA) untuk *artifact removal*, dan normalisasi. Hasil pengujian menunjukkan model GRU yang diusulkan berhasil mencapai akurasi 94,14%, dengan nilai precision dan recall seimbang (94%), serta F1-score 0,94 untuk kedua kelas (kecanduan dan non-kecanduan). Temuan ini menunjukkan bahwa arsitektur GRU sangat efektif untuk membedakan pola aktivitas otak antara individu pecandu dan non-pecandu. Penelitian ini berkontribusi menyediakan landasan ilmiah bagi pengembangan alat bantu diagnosis otomatis yang lebih akurat untuk menunjang program diagnosis dan rehabilitasi.

Kata Kunci: Electroencephalography; Deep Learning; Pornografi; GRU; Signal EEG

Abstract– Objective detection of pornography addiction remains a significant challenge, often hindering effective clinical intervention. This study aims to develop a Deep Learning classification model to non-invasively detect pornography addiction based on Electroencephalography (EEG) signals. This research implements a Gated Recurrent Unit (GRU) architecture to analyze EEG data obtained from 14 respondents using 19 channels. The raw data was processed through filtering, Independent Component Analysis (ICA) for artifact removal, and normalization stages. Test results showed the proposed GRU model achieved an accuracy of 94.14%, with balanced precision and recall values (94%), and an F1-score of 0.94 for both classes (addiction and non-addiction). These findings indicate that the GRU architecture is highly effective in distinguishing brain activity patterns between addicted and non-addicted individuals. This research contributes a scientific foundation for the development of more accurate automated diagnostic tools to support diagnosis and rehabilitation programs.

Keywords: Electroencephalography; Deep Learning; Pornography; GRU; EEG Signals

1. PENDAHULUAN

Perkembangan teknologi informasi yang pesat telah memberikan dampak signifikan bagi kehidupan manusia[1]. Kondisi ini semakin mengkhawatirkan di Indonesia. Menurut laporan National Center for Missing and Exploited Children (NCMEC) pada tahun 2022, Indonesia menempati urutan ke-4 dunia dalam kasus pornografi anak[2]. Secara keseluruhan, tercatat sekitar 5,56 juta kasus pornografi daring yang meningkat selama empat tahun terakhir, menjadikan Indonesia berada di peringkat ke-2 di ASEAN setelah Filipina. Fakta ini menunjukkan bahwa adiksi terhadap pornografi bukan sekadar fenomena sosial, tetapi juga masalah neuropsikologis yang membutuhkan penanganan ilmiah dan objektif[3], [4].

Beberapa penelitian telah berupaya mendeteksi adiksi pornografi dan kondisi neuropsikologis terkait menggunakan Electroencephalography (EEG). Misalnya Saputra dan Movitaria (2022) menganalisis kemampuan kognitif pada anak pecandu pornografi[5]. Penelitian sebelumnya yang menjadi dasar langsung studi ini juga telah mengeksplorasi metode *machine learning* klasik, yaitu Support Vector Machine (SVM)[6], untuk tugas klasifikasi ini. Di sisi lain, tinjauan sistematis oleh Rivera et al. (2022) melaporkan bahwa akurasi model *deep learning* untuk klasifikasi adiksi umumnya hanya berkisar 80–90%[7]. Studi lain seperti Pandey dan Seeja (2022) yang berfokus pada pengenalan emosi menggunakan EEG mencapai akurasi 88,7%[8]. Sementara Prasetya et al. (2025) menunjukkan efektivitas *deep learning* untuk klasifikasi berbasis citra[9].

Dari studi-studi tersebut, terlihat adanya kesenjangan penelitian (*research gap*) yang jelas. Pertama, metode klasik seperti SVM, meskipun berguna, pada dasarnya tidak dirancang untuk menangani data sekuensial yang memiliki dependensi temporal kompleks seperti sinyal EEG. SVM memperlakukan fitur secara independen dan berpotensi kehilangan pola-pola penting yang tersembunyi dalam urutan waktu. Kedua, arsitektur *deep learning* lain yang dirancang untuk sekuens (seperti LSTM) seringkali memiliki parameter yang sangat besar sehingga membutuhkan komputasi yang berat[10], [11]. Ketiga, dibutuhkan model yang dapat secara efisien menganalisis sinyal EEG dari tiga tugas kognitif (M, ET, R) secara bersamaan untuk mendapatkan akurasi yang lebih tinggi dari rentang 80-90% yang dilaporkan Rivera et al.

Untuk mengisi kesenjangan tersebut, penelitian ini mengusulkan model *deep learning* menggunakan arsitektur Gated Recurrent Unit (GRU). Keterbaruan utama penelitian ini terletak pada: (1) Penggunaan arsitektur GRU *multi-layer* yang lebih efisien dan optimal untuk menangkap dependensi temporal sinyal EEG dibandingkan LSTM; (2) Penggabungan spesifik tiga tugas kognitif (M, ET, dan R) yang berkaitan erat dengan fungsi kontrol impuls; dan (3) Fokus pada interpretasi pola klasifikasi dalam konteks neurosains untuk pemahaman yang lebih mendalam.

Berdasarkan rumusan masalah tersebut, tujuan utama penelitian ini adalah (1) Mengembangkan dan memvalidasi model komputasi berbasis GRU yang mampu mengidentifikasi pola sinyal EEG terkait kecanduan pornografi secara akurat; dan (2) Menilai kinerja dan akurasi model GRU yang diusulkan. Manfaat penelitian ini diharapkan dapat memberikan kontribusi akademis dalam pengembangan metode deteksi adiksi berbasis sinyal otak, serta memberikan manfaat praktis sebagai landasan ilmiah untuk pengembangan sistem deteksi dini yang objektif guna menunjang program rehabilitasi.

2. METODOLOGI PENELITIAN

Tujuan penelitian ini adalah mengevaluasi performa GRU dalam mengklasifikasikan tingkat kecanduan pornografi. Tahapan penelitian dirancang secara sistematis, dimulai dari pengumpulan dan pelabelan data, diikuti oleh *preprocessing* sinyal EEG (mencakup *filtering*, *artifact removal* (ICA), normalisasi, dan segmentasi), kemudian dilanjutkan dengan implementasi model (pelatihan dan pengujian arsitektur GRU), dan diakhiri dengan evaluasi kinerja model. Diagram alur penelitian yang lebih rinci ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alur Penelitian

2.1 Pengambilan Data

Penelitian ini menggunakan data dari Kaggle <https://www.kaggle.com/datasets/abdelrahmanmahmoud0/eeg-pornography-addiction>, yang berasal dari Yayasan Kita dan Buah Hati, Jakarta, Indonesia. Para peserta terdiri dari 14 partisipan, yaitu 5 perempuan dan 9 laki-laki. Data diambil menggunakan mesin EEG BrainMaker yang dilengkapi dengan 19 channel. Perekaman dilakukan dengan kecepatan 250 Hz dalam rentang waktu 1 hingga 2 menit, tergantung pada tugas yang diberikan kepada setiap peserta. Setiap partisipan menyelesaikan 9 tugas yang direkam selama sesi eksperimen. Data yang dihasilkan bersifat numerik pada setiap channel EEG.

2.2 Preprocessing

Pada tahapan ini, data EEG mentah dari setiap channel disiapkan untuk diolah oleh model Deep Learning. Proses ini mencakup beberapa langkah krusial untuk memastikan kualitas sinyal dan menghilangkan derau (noise).

1. **Filtering:** Sinyal EEG difilter menggunakan Band-pass Filter pada rentang frekuensi 1-45 Hz. Langkah ini bertujuan untuk menghilangkan baseline drift (frekuensi di bawah 1 Hz) dan derau frekuensi tinggi seperti interferensi otot (EMG). Selain itu, diterapkan Notch Filter pada frekuensi 50 Hz untuk menghilangkan interferensi dari jaringan listrik.
2. **Artifact Removal:** Artefak atau sinyal non-otak yang dapat mengganggu analisis, seperti kedipan mata (EOG) dan gerakan tubuh, diidentifikasi dan dihilangkan menggunakan teknik Independent Component Analysis (ICA). ICA memisahkan sinyal EEG menjadi komponen-komponen independen, memungkinkan komponen artefak untuk diidentifikasi dan dihapus, sehingga sinyal EEG yang dihasilkan lebih bersih.
3. **Normalisasi dan Scaling:** Setelah sinyal bersih diperoleh, proses normalisasi data dan feature scaling dilakukan untuk menyesuaikan skala fitur dalam dataset agar memiliki rentang nilai yang seragam, sehingga membantu model belajar lebih cepat.
4. **Segmentasi:** Sinyal EEG kontinu yang telah bersih kemudian disegmentasi menjadi beberapa bagian (*epoch*) dengan durasi 2 detik. Durasi 2 detik per *epoch* ini dipilih sebagai kompromi optimal untuk menangkap pola aktivitas otak yang relevan tanpa kehilangan konteks temporal, serta untuk menghasilkan jumlah data sekuensial yang memadai untuk pelatihan model GRU.

2.3 Implementasi Model GRU

Gated Recurrent Unit (GRU) adalah bagian dari Recurrent Neural Network (RNN). Model ini lebih sederhana dibandingkan dengan Long Short-Term Memory (LSTM) karena hanya memiliki dua gate utama.

- a. Update gate berfungsi untuk menentukan berapa banyak informasi dari masa lalu yang dibawa ke dalam masa kini.
 - b. Reset gate digunakan untuk mengatur seberapa banyak informasi lama yang akan dilupakan.
- Sederhananya, GRU memungkinkan pemrosesan data sekuensial dengan lebih efisien dibandingkan LSTM, sambil tetap mempertahankan kemampuan dependensi jangka panjang dalam model pembelajaran.

2.4 Evaluasi

Untuk menilai kinerja model GRU yang diusulkan, data dibagi menggunakan metode *train-test split* dengan proporsi 80% untuk data latih dan 20% untuk data uji, seperti yang telah dijelaskan. Kinerja model dievaluasi berdasarkan empat metrik utama yang umum digunakan dalam tugas klasifikasi biner. Pertama, *Confusion Matrix* digunakan untuk memvisualisasikan performa model dengan menunjukkan jumlah *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Kedua, metrik *Accuracy* dihitung untuk mengukur proporsi prediksi yang benar secara keseluruhan. Ketiga, *Precision* digunakan untuk mengukur keakuratan prediksi positif. Keempat, *Recall* (Sensitivitas) digunakan untuk mengukur kemampuan model dalam mengidentifikasi semua kasus positif. Kelima, *F1-Score*, yang merupakan rata-rata harmonik dari *Precision* dan *Recall*, digunakan untuk mengukur keseimbangan antara kedua metrik tersebut.

3. HASIL DAN PEMBAHASAN

3.1 Hasil

3.1.1 Pengambilan Data


Penelitian ini menggunakan data EEG yang dikumpulkan dari 14 partisipan, terdiri atas 5 perempuan dan 9 laki-laki. Distribusi partisipan disusun seimbang antara kelompok kecanduan dan tidak kecanduan pornografi sehingga dataset memiliki representasi kelas yang proporsional. Rekaman EEG dilakukan menggunakan 19 *channel* dengan frekuensi 250 Hz yang mencakup area *frontal*, *central*, *parietal*, *temporal*, dan *occipital*, sehingga data yang diperoleh menggambarkan aktivitas otak dari berbagai fungsi kognitif. Dari sembilan jenis tugas, penelitian ini memfokuskan pada tiga tugas utama: *Memorization* (M), *Executive Task* (ET), dan *Recall* (R), karena ketiganya menunjukkan pola aktivitas otak yang paling relevan dengan aspek kontrol impuls.

△ Subject ID	△ Gender	△ Addiction/NonAd...
14 unique values	Male Female	64% 36%
		NonAddicton Addiction Other (2)
		50% 36% 14%
S1	Male	Addiction
S2	Female	NonAddicton
S3	Female	NonAddicton
S4	Male	NonAddicton
S5	Male	Addiction
S6	Male	Addiction
S7	Male	NonAddicton
S8	Male	NonAddicton
S9	Female	Addiction
S10	Female	Addicton
S11	Female	Addiction
S12	Male	NonAddicton
S13	Male	NonAddicton
S14	Male	Addicton

Gambar 2. Data Partisipan

Setiap partisipan dalam penelitian ini dipasang elektroda EEG di kepala yang terdiri dari 19 channel untuk menangkap aktivitas otak. Perekaman dilakukan dengan kecepatan 250 Hz, memberikan resolusi temporal yang cukup tinggi untuk menangkap sinyal otak secara akurat. Elektroda EEG diposisikan berdasarkan sistem 10-20 International System, mencakup berbagai area otak yang memiliki peran spesifik dalam analisis gelombang otak:

- a. Frontal Pole (Fp1, Fp2) – Terlibat dalam pengambilan keputusan dan kontrol impuls.
- b. Frontal (F3, F4, Fz) – Berhubungan dengan fungsi eksekutif, perhatian, dan pemrosesan informasi.
- c. Central (C3, C4, Cz) – Terkait dengan proses sensorimotor, mengontrol gerakan dan respons tubuh.
- d. Parietal (P3, P4, Pz) – Bertanggung jawab atas pemrosesan sensorik, pengenalan pola, dan integrasi informasi.
- e. Occipital (O1, O2) – Area visual yang berperan dalam pemrosesan gambar dan stimulus visual.
- f. Temporal (T3, T4, T5, T6) – Penting dalam pemrosesan memori, bahasa, dan persepsi auditif.



Gambar 3. Pola Peletakan Elektroda

Setiap partisipan menyelesaikan 9 tugas utama, yang dirancang untuk mengevaluasi respons otak terhadap berbagai stimulus terkait kecanduan pornografi dan kontrol diri.

a) Kondisi Baseline

1. Eye Closed (EC) – Partisipan menutup mata selama 1 menit untuk mencatat aktivitas otak dalam kondisi istirahat.
2. Eye Open (EO) – Partisipan membuka mata selama 1 menit untuk merekam sinyal otak saat terjaga.

b) Pemaparan emosi (Emotional State)

Partisipan diberikan rangsangan gambar dari International Affective Picture System (IAPS) untuk menstimulasi berbagai emosi:

1. Happy (H) – Melihat gambar yang menimbulkan perasaan bahagia.
2. Calm (C) – Melihat gambar yang menciptakan perasaan tenang.
3. Sad (S) – Melihat gambar yang memicu emosi sedih.
4. Fear (F) – Melihat gambar yang menimbulkan ketakutan.

c) Tugas Kognitif dan Eksekutif

1. Memorization Task (M) – Partisipan menghafal 15 kata yang diberikan.
2. Executive Task (ET) – Partisipan diperlihatkan gambar terkait dengan pornografi untuk mengukur reaksi dan kontrol impuls.
3. Recall Task (R) – Partisipan mengingat kembali 15 kata yang sebelumnya dihafalkan.

d) Durasi Perekaman

1. Sebagian besar tugas berlangsung selama 1 menit (89%).
2. Tugas eksekutif atau tugas yang lebih kompleks berlangsung selama 2 menit (11%).

Namun untuk keperluan analisis dalam penelitian ini hanya tugas kognitif dan eksekutif yang digunakan tugas ini dirancang khusus untuk memicu kontrol impuls dan response kognitif para terhadap stimulus gambar yang berkaitan dengan pornografi. Sehingga kondisi ini menjadi paling relevan dalam membedakan antara partisipan yang kecanduan dan yang tidak. Hasil rekaman para peserta disimpan dalam format CSV dan akan dibersihkan menggunakan tahapan EDA (Exploratory Data Analysis). Pada tahap ini, data akan dirapikan dan diperiksa sebelum dilanjutkan ke tahap pra-pemrosesan (preprocessing). Data ditampilkan dan diolah menggunakan pustaka pandas untuk mempermudah pengelolaan file CSV. Perlu dicatat bahwa data EEG memiliki sifat khusus, di mana setiap subjek melakukan beberapa tugas yang berbeda. Pada dataset ini, hasil dari setiap tugas akan digabungkan dengan menggunakan `pd.concat()` untuk memberikan representasi yang lebih utuh tentang status masing-masing subjek, apakah mereka mengalami kecanduan pornografi atau tidak.

	Channel 1 - P4	Channel 2 - O2	Channel 3 - P8	Channel 4 - T8	Channel 5 - C4	Channel 6 - Cz	Channel 7 - Fz	Channel 8 - F4	Channel 9 - Fp2	Channel 10 - F8	...	EC	EO	ET	F	H	M	R	S	gender	porn_addiction
0	74.856281	64.499747	48.983691	-6.168428	78.580174	0.973399	107.123763	89.360670	58.127294	28.575393	...	0	0	0	0	0	0	0	1	1	1
1	69.333678	54.387968	41.821589	-2.033677	66.275204	1.962160	82.254251	59.169122	53.729631	28.011570	...	0	0	0	0	0	0	0	1	1	1
2	36.695152	23.294316	17.671576	-2.393062	27.879321	2.318309	25.264910	2.709672	23.196586	15.951011	...	0	0	0	0	0	0	0	1	1	1
3	-1.704405	-11.383881	-9.768135	-6.422270	-12.223158	1.953945	-28.390078	-47.331406	-11.987905	0.707303	...	0	0	0	0	0	0	0	1	1	1
4	-22.714304	-31.369307	-26.039601	-11.138549	-30.870779	1.453846	-48.765400	-64.675435	-28.855161	-8.054482	...	0	0	0	0	0	0	0	1	1	1

Gambar 4. Fitur fitur pada subjek


3.1.2 Preprocessing

Setelah tahap *Exploratory Data Analysis* (EDA) dan pembersihan data (*cleaning*), dilakukan proses transformasi krusial agar data sesuai dengan arsitektur *Recurrent Neural Network* (RNN). Data EEG yang awalnya berbentuk 2D (*n_samples*, 23) diubah menjadi bentuk tensor 3 dimensi (*samples*, *timesteps*, *features*) melalui proses *reshape*. Dalam penelitian ini, setiap baris diperlakukan sebagai satu *timestep* dengan 29 fitur (setelah penyesuaian), menghasilkan struktur input yang mempertahankan kontinuitas temporal. Transformasi ini

memungkinkan model GRU untuk langsung mempelajari pola dinamika urutan sinyal otak tanpa kehilangan konteks waktu.

3.1.3 Implementasi Model GRU

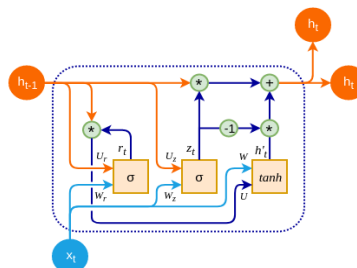
Model Gated Recurrent Unit (GRU) merupakan salah satu varian dari recurrent neural network (RNN) yang dirancang untuk mengolah data berurutan dengan kemampuan mempertahankan informasi dari input sebelumnya. Berbeda dengan feedforward neural network yang hanya memproses data satu arah tanpa mempertimbangkan urutan waktu, GRU mampu menyimpan konteks historis melalui mekanisme gating system. Mekanisme ini memungkinkan model untuk mempertahankan memori dari input sebelumnya dan menggunakan informasi tersebut dalam memprediksi keluaran berikutnya, sehingga lebih efektif dalam memahami hubungan jangka panjang antar data.



Gambar 5. Neural Network

Kelebihan utama GRU terletak pada arsitekturnya yang lebih sederhana dibandingkan Long Short-Term Memory (LSTM), karena hanya memiliki dua gerbang utama yaitu update gate dan reset gate. Struktur yang lebih ringkas ini membuat proses pelatihan GRU lebih cepat dan efisien tanpa mengorbankan kinerja prediksi. Selain itu, jumlah parameter yang lebih sedikit menjadikan GRU lebih hemat dalam penggunaan memori dan sumber daya komputasi, sehingga cocok diterapkan pada sistem dengan keterbatasan perangkat keras. Mekanisme gerbang pada GRU juga membantu mengatasi permasalahan vanishing gradient yang sering terjadi pada RNN konvensional, memungkinkan model untuk belajar pola dependensi jangka panjang secara lebih stabil.

Lebih lanjut, GRU dikenal memiliki kemampuan yang baik dalam menangani data sekuensial dengan panjang variabel, seperti sinyal EEG, teks, atau deret waktu (time series). Beberapa penelitian bahkan menunjukkan bahwa GRU dapat menghasilkan kinerja yang sebanding, atau dalam beberapa kasus melebihi, model LSTM pada dataset berukuran sedang hingga besar. Dengan kombinasi efisiensi komputasi, kestabilan pelatihan, dan kemampuan dalam menangkap konteks temporal, GRU menjadi salah satu model RNN yang banyak digunakan dalam berbagai bidang, termasuk analisis sinyal biomedis, pemrosesan bahasa alami, serta prediksi data ekonomi dan kesehatan.



Gambar 6. Ilustrasi Model GRU

Pada penerapan model GRU kami menerapkan beberapa lapisan yang bertujuan untuk menangkap pola sekuensial dalam data EEG seperti pada lapisan pertama berupa input layer yang terdiri dari model yang menerima input dengan dimensi, yang di mana jumlah fitur dalam dataset EEG akan menentukan ukuran input.

```
inputs = tf.keras.Input(shape=(X_train.shape[1],))
x = tf.keras.layers.Reshape((-1, 29))(inputs)
```

Gambar 7. Input Layer pada model GRU

Dilanjutkan dengan lapisan GRU untuk menangani data sekuensial yang dimana pada penelitian ini kami menerapkan tiga lapisan GRU. Pada GRU lapisan pertama kami menerapkan 128 unit untuk menangkap pola kompleks dari input data EEG. Dilanjutkan dengan lapisan kedua yang mengurangi jumlah unit menjadi 64 ini bertujuan untuk mereduksi kompleksitas model sambil tetap mempertahankan informasi penting dari lapisan sebelumnya. Pada lapisan ketiga jumlah unit kembali diperkecil menjadi 32 yang merupakan pemrosesan akhir sebelum masuk ke dalam tahap fully connected layer.

```
x = tf.keras.layers.GRU(128, return_sequences=True)(x)
x = tf.keras.layers.GRU(64, return_sequences=True)(x)
x = tf.keras.layers.GRU(32)(x)
```

Gambar 8. Lapisan Pada Model GRU

Selanjutnya penerapan dense layer dan dropout dimana pada lapisan dense penggunaan unit berjumlah 32 dengan penerapan aktivasi relu untuk meningkatkan kemampuan model dalam menangkap pola kompleks. Sebelum tahap output setelah melalui dense layer selanjutnya masuk ke dalam tahap dropout yang memiliki fungsi mengurangi resiko overfitting dengan menetapkan nilai sebesar 50% unit secara acak menjadi nol saat pelatihan.

```
x = tf.keras.layers.Dense(32, activation='relu')(x)
x = tf.keras.layers.Dropout(0.5)(x)
```

Gambar 9. Dropout Layer Pada GRU

Untuk menjelaskan rancangan model yang digunakan dalam penelitian ini, disusun tabel arsitektur GRU yang memuat susunan dalam tabel berikut:

Table 1. Arsitektur GRU yang digunakan


No	Parameter	Konfigurasi	Keterangan
Lapisan (Layer)			
1	Input Layer	shape=(input_shape,) kemudian reshape menjadi (-1, 23)	di- Input EEG dalam bentuk vektor yang diubah menjadi urutan (sequence) dengan 23 fitur per timestep.
2	GRU Layer 1	128 units, return_sequences=True	Mengekstrak pola temporal tingkat rendah dari sinyal EEG.
3	GRU Layer 2	64 units, return_sequences=True	Menangkap representasi temporal tingkat menengah.
4	GRU Layer 3	32 units	Mengekstrak fitur temporal tingkat tinggi sebelum masuk ke lapisan fully connected.
5	Dense Layer	32 units, activation='relu'	Lapisan fully connected non-linear untuk pemetaan fitur ke ruang representasi akhir.
6	Dropout Layer	rate=0.5	Mencegah overfitting dengan menonaktifkan sebagian neuron selama pelatihan.
7	Output Layer	1 unit, activation='sigmoid'	Menghasilkan probabilitas antara 0–1 untuk klasifikasi biner.
Parameter Pelatihan			
8	Optimizer	Adam	Algoritma optimisasi adaptif yang menyesuaikan learning rate tiap parameter.
9	Loss Function	Binary Crossentropy	Digunakan untuk klasifikasi biner (output sigmoid).
10	Batch Size	1500	Jumlah sampel yang diproses dalam satu iterasi pelatihan.
11	Epochs	15	Jumlah siklus penuh pelatihan pada seluruh dataset.
12	Metrics	Accuracy	Digunakan untuk mengukur performa model pada data pelatihan dan validasi.

3.1.4 Evaluasi

Setelah data selesai diproses dengan menggunakan data latih selanjutnya model Gated Recurrent Unit (GRU) dievaluasi untuk menguji performa model terhadap data uji. Tahapan ini bertujuan menilai sejauh mana model mampu mengklasifikasikan peserta dalam dua kategori, yaitu kecanduan pornografi dan tidak kecanduan, berdasarkan pola aktivitas otak yang terekam melalui sinyal EEG.

3.1.4.1 Confusion Matrix

Untuk mengevaluasi kinerja model klasifikasi yang dibangun, penelitian ini menggunakan confusion matrix sebagai alat ukur utama.



Gambar 10. Hasil Confusion Matrix Dari Model

Berdasarkan gambar confusion matrix menunjukkan kinerja model dalam memprediksi :

- 79.184 sample data non-kecanduan dengan benar (True Negative),
- 78.968 sample data kecanduan dengan benar (True Positive),
- 4.816 sample data non-kecanduan salah diklasifikasikan sebagai kecanduan (False Positive),
- 5.032 sample data kecanduan salah diklasifikasikan sebagai non-kecanduan (False Negative).

3.1.4.2 Classification Report

	precision	recall	f1-score	support
0	0.9402	0.9427	0.9415	84000
1	0.9425	0.9401	0.9413	84000
accuracy			0.9414	168000
macro avg	0.9414	0.9414	0.9414	168000
weighted avg	0.9414	0.9414	0.9414	168000

Gambar 11. Perhitungan klasifikasi dengan Report.

Hasil yang diperoleh dari classification report menunjukkan bahwa akurasi model secara keseluruhan adalah 94.14%. Angka ini menandakan bahwa model dapat mengklasifikasikan data uji dengan tingkat ketepatan yang sangat tinggi. Untuk nilai precision dan recall juga sangat seimbang; masing-masing nilai berada di kisaran 94% untuk kedua kelas, menunjukkan bahwa model tidak bias terhadap salah satu kelas. Nilai F1-Score dalam menentukan kategori kedua kelas hampir sama persis, yaitu berkisar 0.9415 untuk kelas 0 (tidak kecanduan) dan 0.9413 untuk kelas 1 (kecanduan). Ini menandakan model memiliki keseimbangan yang baik antara precision dan recall, memberikan gambaran performa yang komprehensif.

3.2 Pembahasan

Hasil penelitian ini menunjukkan bahwa model GRU yang diusulkan mampu mengklasifikasikan kondisi kecanduan pornografi berdasarkan sinyal EEG dengan akurasi mencapai 94,14%. Temuan ini sejalan dengan

penelitian Saputra yang menyoroti dampak kognitif pada pecandu, serta Fa'ida yang menekankan dampak adiktif[3], [5].

Komparasi dengan Penelitian Terdahulu Secara komparatif, hasil akurasi 94,14% ini menunjukkan peningkatan yang signifikan dibandingkan penelitian-penelitian terdahulu.

1. Capaian ini melampaui rata-rata akurasi model *deep learning* untuk klasifikasi gangguan mental berbasis EEG yang dilaporkan oleh Rivera et al. (2022), yang umumnya berkisar antara 80–90%[7].
2. Performa model ini juga lebih unggul dibandingkan studi klasifikasi emosi berbasis EEG oleh Pandey dan Seeja (2022) yang mencatatkan akurasi 88,7% menggunakan *Deep Neural Network*[8].
3. Dibandingkan dengan metode klasik seperti *Support Vector Machine* (SVM) yang sering digunakan dalam analisis EEG konvensional, pendekatan GRU ini menawarkan keunggulan dalam memproses data sekuensial tanpa perlu ekstraksi fitur manual yang[6].

Analisis Teknis Keunggulan performa ini membuktikan efektivitas arsitektur GRU dalam menangani data *time-series*. Kemampuan GRU mempertahankan memori jangka panjang melalui mekanisme *gating* (gerbang *update* dan *reset*) memungkinkannya menangkap pola temporal kompleks dalam sinyal EEG yang seringkali terlewatkan oleh model non-sekuensial. Temuan ini sejalan dengan tinjauan Merlin Praveena et al. (2022)[11], yang menyoroti bahwa arsitektur berbasis RNN seperti GRU adalah pendekatan paling *robust* untuk analisis sinyal biomedis[12], [13]. Selain itu, penggunaan GRU terbukti lebih efisien secara komputasi dibandingkan LSTM karena memiliki parameter yang lebih sedikit namun tetap mempertahankan stabilitas akurasi [14], [15], [16]. Efektivitas GRU dalam menangani sinyal EEG yang kompleks juga dikonfirmasi oleh Moctezuma et al. (2024) yang menerapkannya pada klasifikasi tahapan tidur[17], serta Gao et al. (2022) yang menggunakannya untuk *decoding* sinyal motorik[18].

Implikasi dan Keterbatasan Temuan ini memiliki implikasi praktis yang luas. Di bidang klinis, model ini berpotensi menjadi alat bantu deteksi dini yang objektif. Namun, penelitian ini memiliki keterbatasan, terutama pada ukuran sampel yang kecil ($n=14$) dan penggunaan data sekunder yang telah melalui tahap *preprocessing*. Kondisi *noise* pada perekaman *real-time* di lapangan mungkin memberikan tantangan berbeda. Oleh karena itu, penelitian selanjutnya disarankan untuk menguji model pada data sinyal mentah dengan populasi yang lebih besar, atau mengeksplorasi pendekatan *multimodal* dengan menggabungkan data EEG dan perilaku digital untuk validasi yang lebih komprehensif[19].

4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa penerapan model *Deep Learning* berbasis Gated Recurrent Unit (GRU) memiliki efektivitas tinggi dalam mendeteksi kecanduan pornografi melalui analisis sinyal Electroencephalography (EEG). Model yang dikembangkan mampu mengenali pola aktivitas otak yang membedakan individu pecandu dan non-pecandu dengan tingkat akurasi mencapai 94,14%, sehingga menjawab rumusan masalah utama penelitian. Performa ini juga didukung oleh nilai *precision*, *recall*, dan *F1-score* yang seimbang di kisaran 0,94. Secara teoretis, penelitian ini memperkuat bukti bahwa pendekatan *deep learning* sekuensial seperti GRU efektif dalam menganalisis data sinyal otak. Secara praktis, temuan ini membuka peluang bagi pengembangan sistem deteksi dini otomatis yang objektif guna menunjang proses diagnosis maupun program rehabilitasi. Meskipun hasil yang diperoleh cukup menjanjikan, penelitian ini memiliki beberapa keterbatasan, terutama pada ukuran sampel yang kecil ($n=14$) dan penggunaan data sekunder yang telah melalui *preprocessing*. Untuk penelitian selanjutnya, disarankan memperluas jumlah partisipan, menggunakan data mentah untuk pengujian yang lebih realistis, serta mengeksplorasi arsitektur lain atau membandingkan performa GRU dengan algoritma klasik seperti SVM dan Random Forest agar diperoleh gambaran performa yang lebih komprehensif.

REFERENCES

- [1] S. Mufti Prasetyo, R. Gustiawan, and F. Rizzel Albani, "BIIKMA : Buletin Ilmiah Ilmu Komputer dan Multimedia Analisis Pertumbuhan Pengguna Internet Di Indonesia," vol. 2, no. 1, 2024, [Online]. Available: <https://jurnalmahasiswa.com/index.php/biikma>
- [2] R. Nastiti, "Strategi Pencegahan Pornografi dan Pornoaksi Berbasis Pendidikan Karakter Islam pada Remaja di Era Digital: Tinjauan Tafsir Ath-Thabari An-Nur Ayat 30-31," *J. Miftahul Ilmi J. Pendidik. Agama Islam*, vol. 2, pp. 131–144, Apr. 2025, doi: 10.59841/miftahulilmi.v2i2.101.
- [3] S. Ahmada Fa'ida and R. D. Noorrizki, "Dampak Adiktif Pornografi pada Remaja," *J. Flourishing*, vol. 3, no. 7, pp. 278–285, doi: 10.17977/10.17977/um070v3i72023p278-285.
- [4] A. N. Ramadani, "Tahun 2023 ANALISIS KESTABILAN MODEL MATEMATIKA KECANDUAN PORNOGRAFI DI KALANGAN PELAJAR DAN MAHASISWA".

- [5] S. Saputra and M. Adyna Movitaria, "ANALISIS KEMAMPUAN KOGNITIF PADA REMAJA PECANDU PORNOGRAFI," vol. 2, no. 2, pp. 178–191, 2022, doi: 10.55062/2021/IJPI.
- [6] D. Supantini, D. Gunawan, D. Harnandi, and D. Chandrasasmita, "Classification of Electroencephalogram Signal of Sleeping Condition as Output of EEG Digital Device of Clinical Neurophysiology Laboratory of Immanuel Hospital Using Support Vector Machine," vol. 6, no. 2, 2022, doi: 10.29099/ijair.v6i2.447.
- [7] M. J. Rivera, M. A. Teruel, A. Maté, and J. Trujillo, "Diagnosis and prognosis of mental disorders by means of EEG and deep learning: a systematic mapping study," *Artif. Intell. Rev.*, vol. 55, no. 2, pp. 1209–1251, Feb. 2022, doi: 10.1007/s10462-021-09986-y.
- [8] P. Pandey and K. R. Seeja, "Subject independent emotion recognition from EEG using VMD and deep learning," *J. King Saud Univ. - Comput. Inf. Sci.*, vol. 34, no. 5, pp. 1730–1738, 2022, doi: <https://doi.org/10.1016/j.jksuci.2019.11.003>.
- [9] O. Prasetia, S. Machfud, P. Rosyani, and B. Agustian, "BULLETIN OF COMPUTER SCIENCE RESEARCH Klasifikasi Gender Berbasis Citra Wajah Menggunakan Clustering Dan Deep Learning," *Media Online*, vol. 5, no. 4, pp. 770–777, 2025, doi: 10.47065/bulletincsr.v5i4.581.
- [10] M. Kurniawan, A. Rachman, A. Pakarbudi, J. T. Informatika, T. Adhi, and T. Surabaya, "Kurniawan, Review Pemanfaatan Data Electroencephalogram (EEG) dengan metode Convolution Neural Network 143 Review Pemanfaatan Data Electroencephalogram (EEG) dengan metode Convolution Neural Network."
- [11] D. Merlin Praveena, D. Angelin Sarah, and S. Thomas George, "Deep Learning Techniques for EEG Signal Applications – A Review," *IETE J. Res.*, vol. 68, no. 4, pp. 3030–3037, July 2022, doi: 10.1080/03772063.2020.1749143.
- [12] T. R. Mim *et al.*, "GRU-INC: An inception-attention based approach using GRU for human activity recognition," *Expert Syst. Appl.*, vol. 216, p. 119419, 2023, doi: <https://doi.org/10.1016/j.eswa.2022.119419>.
- [13] M. Bouchane, W. Guo, and S. Yang, "Hybrid CNN-GRU Models for Improved EEG Motor Imagery Classification," *Sensors*, vol. 25, no. 5, Mar. 2025, doi: 10.3390/s25051399.
- [14] K. Prayogi, W. Gata, and D. P. Kussanti, "Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU," *Jutisi J. Ilm. Tek. Inform. Dan Sist. Inf.*, vol. 13, no. 1, pp. 647–658, 2024.
- [15] R. Nugraha, Abdul Rezha Efrat Najaf, and Reisa Permatasari, "BCA Stock Price Prediction Using Time Series Method With GRU (Gated Recurrent Unit)," *J. Teknol. DAN OPEN SOURCE*, vol. 8, no. 2, pp. 432–440, Oct. 2025, doi: 10.36378/jtos.v8i2.4500.
- [16] T. Perumal, N. Mustapha, R. Mohamed, and F. M. Shiri, "A Comprehensive Overview and Comparative Analysis on Deep Learning Models," *J. Artif. Intell.*, vol. 6, no. 1, pp. 301–360, 2024, doi: 10.32604/jai.2024.054314.
- [17] L. A. Moctezuma, Y. Suzuki, J. Furuki, M. Molinas, and T. Abe, "GRU-powered sleep stage classification with permutation-based EEG channel selection," *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-68978-4.
- [18] S. Gao, J. Yang, T. Shen, and W. Jiang, "A Parallel Feature Fusion Network Combining GRU and CNN for Motor Imagery EEG Decoding," *Brain Sci.*, vol. 12, no. 9, Sept. 2022, doi: 10.3390/brainsci12091233.
- [19] P. K. Sahu and K. Jain, "Schizophrenia diagnosis using the GRU-layer's alpha-EEG rhythm's dependability," *Psychiatry Res. Neuroimaging*, vol. 344, p. 111886, 2024, doi: <https://doi.org/10.1016/j.psychresns.2024.111886>.