

Deteksi Penyakit Epilepsi Secara Real-Time menggunakan Algoritma K-Nearest Neighbors (KNN) Berbasis Sinyal Electroencephalography

Maria Elida Tarigan*, Aldo Sofyan Zebua, Firhot Manurung, Jasmine Mutiara Bintang, Dhanny Rukmana Manday

Fakultas Sains dan Teknologi, Program Studi Teknik Informatika, Universitas Prima Indonesia, Kota Medan, Indonesia

Email: ¹mariatarigan858@gmail.com*, ²aldozebua7@gmail.com, ³firhotmanurung09@gmail.com,

⁴jasminemutiara0303@gmail.com, ⁵dhannyrukmanamanday@unprimdn.ac.id

Correspondence Author Email: mariatarigan858@gmail.com*

Submitted: 29/05/2025; Accepted: 09/06/2025; Published: 30/06/2025

Abstrak– Epilepsi adalah gangguan saraf kronis yang ditandai dengan kejang yang terjadi berulang kali akibat aktivitas listrik yang tidak normal di dalam otak. Menurut informasi dari WHO, lebih dari 50 juta orang di seluruh dunia menderita epilepsi, dengan sekitar 80% dari mereka berada di negara-negara yang sedang berkembang, termasuk Indonesia. Di Indonesia sendiri, diperkirakan ada antara 2,7 sampai 5,4 juta orang yang mengalami epilepsi, sementara fasilitas untuk diagnosis yang cepat dan tepat masih terbatas. Proses untuk mendiagnosis epilepsi umumnya bergantung pada analisis manual dari sinyal EEG yang memerlukan waktu lama dan keahlian khusus. Penelitian ini bertujuan untuk mengembangkan sistem deteksi penyakit epilepsi secara real-time dengan menggunakan algoritma K-Nearest Neighbors (KNN), sebagai opsi yang efisien dan terjangkau. Berbagai metode sebelumnya, seperti SeizureTransformer, CNN-LSTM, serta teknik yang berbasis entropi dan ensemble, telah menunjukkan hasil yang menggembirakan tetapi terhambat oleh kompleksitas dan kebutuhan komputasi yang tinggi. KNN memiliki kelebihan dalam hal kecepatan dan kemudahan implementasi, meskipun pemanfaatannya dalam konteks EEG epilepsi masih cukup minim. Melalui penelitian ini, sistem berbasis KNN dirancang untuk mendeteksi penyakit secara langsung dari sinyal EEG, dengan harapan dapat meningkatkan akurasi diagnosis dan efisiensi waktu dalam layanan kesehatan. Diharapkan sistem ini dapat memberikan alternatif praktis dalam penanganan epilepsi, terutama di daerah-daerah yang memiliki keterbatasan dalam fasilitas medis seperti Kota Medan.

Kata Kunci: Epilepsi, EEG, KNN, Deteksi Kejang, Real-Time.

Abstract– Epilepsy is a chronic neurological disorder characterized by seizures that occur repeatedly due to abnormal electrical activity in the brain. According to information from the WHO, more than 50 million people worldwide suffer from epilepsy, with about 80% of them being in developing countries, including Indonesia. In Indonesia alone, it is estimated that between 2.7 and 5.4 million people have epilepsy, while facilities for a quick and accurate diagnosis are still limited. The process for diagnosing epilepsy generally relies on manual analysis of EEG signals which takes a long time and specialized expertise. This study aims to develop a real-time epilepsy detection system using the K-Nearest Neighbors (KNN) algorithm, as an efficient and affordable option. Previous methods, such as SeizureTransformer, CNN-LSTM, as well as entropy-based and ensemble-based techniques, have shown encouraging results but have been hampered by complexity and high computational requirements. KNN has advantages in terms of speed and ease of implementation, although its use in the context of epilepsy EEG is still quite minimal. Through this research, the KNN-based system is designed to detect diseases directly from EEG signals, in the hope of improving diagnostic accuracy and time efficiency in healthcare. It is hoped that this system can provide a practical alternative in handling epilepsy, especially in areas that have limitations in medical facilities such as Medan City. Keywords: epilepsy, EEG, KNN, seizure detection, Real-time.

Keywords: Detection; Epilepsy; EEG; K-Nearest Neighbors (KNN)

1. PENDAHULUAN


Epilepsi merupakan salah satu gangguan neurologis kronis yang paling umum di dunia. ditandai dengan kejang berulang yang disebabkan oleh gangguan aktivitas listrik di otak[1][2]. Kelainan saluran ion dapat membuat neuron terlalu aktif, memicu gangguan seperti kejang[3]. Menurut *World Health Organization* (WHO), diperkirakan lebih dari 50 juta orang di seluruh dunia hidup dengan epilepsi, menjadikannya salah satu gangguan saraf paling umum secara global. Sekitar 80% penderita epilepsi berada di negara berkembang, termasuk Indonesia, di mana kesadaran masyarakat terhadap penyakit ini masih relatif rendah [4]. Di Indonesia, angka kejadian epilepsi diperkirakan mencapai 1-2% dari total jumlah penduduk. Dengan jumlah penduduk Indonesia yang mencapai lebih dari 270 juta jiwa, diperkirakan terdapat sekitar 2,7 hingga 5,4 juta penderita epilepsi. Tingginya jumlah penderita epilepsi yang memerlukan diagnosis cepat dan akurat menjadi tantangan tersendiri bagi dunia medis. proses diagnosis epilepsi di banyak fasilitas kesehatan masih mengandalkan analisis manual sinyal elektroensefalografi (EEG), yang tidak hanya membutuhkan keahlian khusus, tetapi juga memerlukan waktu lama, serta rentan terhadap kesalahan subjektif. Kondisi ini menjadi hambatan besar dalam penyediaan layanan kesehatan yang cepat dan akurat. Di sisi lain, analisis data EEG (*Electroencephalogram*) secara manual membutuhkan waktu lama, melibatkan proses yang kompleks, serta memerlukan keahlian tinggi dari tenaga medis, khususnya di kota besar seperti Medan [5]. Di Kota Medan sendiri, kasus epilepsi cukup tinggi, dan kebutuhan akan sistem diagnosis cepat dan akurat menjadi sangat penting, mengingat kejang akibat epilepsi dapat menyebabkan gangguan kesadaran, kecelakaan fisik, kerusakan saraf, hingga risiko kematian jika tidak ditangani dengan segera. Oleh karena itu, dibutuhkan solusi berbasis teknologi yang dapat mendeteksi kondisi epilepsi secara otomatis dan efisien untuk membantu proses diagnosis yang lebih cepat, akurat, dan terjangkau [6]. Penelitian terkait Seizure Transformer (2025) Wu et al. mengembangkan model *SeizureTransformer* yang menggabungkan arsitektur U-Net dan Transformer untuk mendeteksi kejang pada setiap titik waktu dalam rekaman EEG panjang. Model ini menunjukkan kinerja unggul dalam kompetisi deteksi kejang

internasional, namun kompleksitasnya tinggi dan memerlukan sumber daya komputasi besar [7]. Pendekatan Real-Time dengan STFT dan GoogleNet CNN (2024) Sebuah studi mengusulkan metode deteksi kejang real-time menggunakan transformasi Fourier waktu-singkat (STFT) dan jaringan saraf konvolusional GoogleNet. Metode ini mencapai akurasi 97,74% dengan waktu pemrosesan 0,02 detik per segmen EEG 2 detik, namun implementasinya masih terbatas pada lingkungan laboratorium [8]. Deteksi Kejang dengan Entropi dan Pembelajaran Ensemble (2023) Dastgoshadeh dan Rabiei mengembangkan sistem deteksi kejang menggunakan fitur entropi dari sinyal EEG dan algoritma pembelajaran ensemble. Meskipun mencapai akurasi tinggi, pendekatan ini belum diuji dalam konteks real-time [9]. Dalam penelitian ini metode yang digunakan dalam pengolahan sinyal EEG yaitu algoritma K-Nearest Neighbors (KNN). Algoritma K-Nearest Neighbors (KNN) yang menggunakan algoritma supervised dimana hasil dari query instance yang baru diklasifikasikan berdasarkan mayoritas dari label class [10]. Dalam konteks deteksi epilepsi menggunakan data EEG, KNN bekerja dengan prinsip dasar pencarian "tetangga terdekat" dari data yang belum diketahui kelasnya. Proses ini dimulai dengan menghitung jarak antara data yang akan diklasifikasikan dengan data data lain yang sudah diketahui kelasnya dalam ruang fitur. Penelitian ini bertujuan mengembangkan sistem deteksi real-time menggunakan algoritma klasifikasi cepat yakni K-Nearest Neighbors (KNN) pada data EEG untuk meningkatkan layanan kesehatan dengan mengimplementasikan teknologi, serta membandingkan kelas model yang dibangun dan menganalisis faktor yang mempengaruhi akurasi[11]. Kombinasi CNN-LSTM untuk Klasifikasi Epilepsi (2023) Wang et al. mengusulkan metode pembelajaran mendalam yang menggabungkan CNN dan LSTM untuk klasifikasi multi-kelas status epilepsi. Meskipun model ini menunjukkan kinerja tinggi, kompleksitas arsitekturnya dapat menjadi hambatan untuk implementasi real-time [12]. Arsitektur IoT Adaptif Berbasis KNN (2023) ElSayed et al. mengembangkan sistem deteksi kejang berbasis K-Nearest Neighbors (KNN) yang dapat disesuaikan secara individu dalam waktu pelatihan kurang dari empat detik. Sistem ini menunjukkan akurasi rata-rata 94,5% dan cocok untuk implementasi real-time pada perangkat IoT[13]. Dari kajian-kajian tersebut, tampak bahwa walaupun banyak metode telah dikembangkan untuk mendeteksi penyakit epilepsi, sebagian besar masih menghadapi kesulitan terkait kompleksitas model, diperlukan sumber daya komputasi yang besar, dan batasan dalam penerapan secara langsung. Metode KNN memberikan alternatif yang lebih efisien dan cepat, tetapi belum banyak diteliti lebih lanjut dalam konteks deteksi penyakit epilepsi secara langsung berdasarkan sinyal EEG. Penelitian bertujuan untuk merancang serta menerapkan sistem yang dapat mendeteksi kejang epilepsi secara langsung dengan memanfaatkan algoritma K-Nearest Neighbors (KNN) yang berbasis pada sinyal EEG. Sistem ini diharapkan dapat memberikan kontribusi nyata dalam penyediaan layanan kesehatan yang lebih baik, khususnya dalam pemantauan dan penanganan epilepsi yang cepat dan akurat.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Dalam studi ini, terdapat tahapan penelitian yang terdiri dari beberapa fase yang akan dilalui untuk menjalankan penelitian ini sebagai berikut :



Gambar 1 Tahapan Penelitian

1. Pengumpulan Dataset EEG. Dataset terdiri dari lima kelas (A hingga E), namun hanya set A, B, dan E yang digunakan dalam penelitian:
 - a. Set A: EEG individu sehat dengan kondisi mata terbuka.
 - b. Set B: EEG individu sehat dengan kondisi mata tertutup.
 - c. Set E: EEG dari penderita epilepsi saat kejang.
 Setiap set berisi 100 file dengan 4096 sampel per file dalam format ASCII.
2. *Pra-pemrosesan data* : proses yang diperlukan untuk mempersiapkan data sebelum masuk ke dalam model. Prosesnya adalah sebagai berikut:
 - a. Segmentasi dan Normalisasi Setiap file sinyal EEG berdurasi 23,6 detik (4096 sampel), kemudian bagi sinyal menjadi segmen tetap sepanjang 900 sampel dan tanpa overlap. Setelah itu, data

- a. dinormalisasi kembali dengan *z-score normalization*.
 - b. *Filter dan Transformasi* Data difilter menggunakan *Butterworth band-pass* filter dengan batas frekuensi 0.5 Hz – 40 Hz, yang bertujuan menghilangkan noise frekuensi rendah dan menghilangkan noise frekuensi tinggi. Setelah difilter, sinyal kemudian dinormalisasi menggunakan *z-score normalization* kembali bertujuan agar sinyal memiliki distribusi dengan rata rata nol dan simpangan baku satu. Untuk mengatasi gangguan ekstrem, maka nilai amplitudo sinyal dipotong (clipping) pada batas $\pm 500 \mu V$.
 - c. *Ekstraksi fitur* menggunakan transformasi wavelet diskrit (Discrete Wavelet Transform/DWT) dengan wavelet Daubechies 4 (db4) hingga level dekomposisi ketiga.
3. Pembagian data training dan testing. Setelah data dikumpulkan dalam 1 folder berisi set A-B-E dan dibersihkan dengan menghilangkan NaN dan angka negatif (-). Lalu, langkah selanjutnya adalah membagi data menjadi dua set utama yakni data pelatihan (training data) dan data pengujian (testing data). Training data digunakan untuk melatih sebuah model. Sedangkan testing data digunakan untuk menguji kinerja model setelah dilatih. Persiapan data ini memisahkan dataset menjadi 80% data pelatihan dan 20% data pengujian.
4. *Classification* adalah proses dalam machine learning dan data mining yang mengelompokkan objek atau data pada kelas atau kategori menurut karakteristik yang diperoleh. Proses penerapan K-Nearest Neighbors (KNN) seperti menentukan parameter K, yang dipilih sebagai jumlah tetangga terdekat (misalnya, K = 3 atau K = 5).
5. *Result* adalah hasil dari penelitian ini dengan metode yang diterapkan yakni K-Nearest Neighbors (KNN) yang dapat mengklasifikasikan objek berdasarkan jenisnya.

2.2 Algoritma K-Nearest Neighbors

Merupakan salah satu algoritma pembelajaran mesin sederhana. Hal ini hanya didasarkan pada gagasan bahwa suatu objek yang dekat satu sama lain juga akan memiliki karakteristik yang mirip. Ini berarti jika kita mengetahui ciri-ciri dari salah satu objek, maka kita juga dapat memprediksi objek lain berdasarkan tetangga terdekatnya. K-NN adalah improvisasi lanjutan dari teknik Klasifikasi Nearest Neighbor. Algoritma K-NN salah satu metode untuk melakukan klasifikasi yang sudah digunakan diberbagai bidang [14]. memiliki tujuan untuk mengklasifikasi obyek baru berdasarkan atribut data [15]. training sample Hal ini didasarkan pada gagasan bahwa setiap contoh baru dapat diklasifikasikan oleh suara mayoritas dari k tetangga, di mana k adalah bilangan bulat positif, dan biasanya dengan jumlah kecil [16]. Klasifikasi K-NN membutuhkan metrik dan integer positif k. Aturan K-NN memegang posisi sampel pelatihan dan kelas mereka. Saat memutuskan tentang data masuk baru. Tujuan algoritma ini adalah untuk mengklasifikasikan objek baru berdasarkan nilai atribut dan data latih [17]. Algoritma K-NN merupakan sebuah algoritma yang dikenal dengan non numerik dalam data mining, yang bias digunakan untuk melakukan klasifikasi ataupun regresi. Dalam melakukan klasifikasi menggunakan sebuah algoritma tertentu membutuhkan sebuah dataset yang terdiri dari data training dan data testing. Algoritma K-NN yakni merupakan sebuah proses supervised yang memiliki arti bahwa pada proses K-NN ini memerlukan informasi training guna dilakukannya klasifikasi terhadap suatu objek yang memiliki jarak terdekat. Adapun prinsip kerja pada K-NN ini adalah dengan mencari jarak euclidean atau jarak terdekat berdasarkan nilai k. dan adapun persamaan yang dapat digunakan dalam algoritma K-NN adalah [18]:

$$di = \sqrt{\sum_{i=1}^n (x_{ij})^2} \quad (1)$$

Keterangan :

d_i = Jarak Euclidean antara data ke- i (data latih) dan titik data uji

n = Jumlah fitur atau dimensi data

x_{ij} = Nilai fitur ke- j dari data latih ke- i

p_j = Nilai fitur ke- j dari data uji (data yang ingin diklasifikasikan)

Σ = Penjumlahan dari indeks $j = 1$ sampai n

(.)² = Kuadrat dari selisih nilai antar fitur

$\sqrt{\quad}$ = Akar kuadrat dari jumlah kuadrat selisih (hasil akhir jarak)


3. HASIL DAN PEMBAHASAN

3.1 Persiapan Data

Dataset yang digunakan berasal dari Universitas Bonn yang terdiri dari lima (5) kelas yakni set A, B, C, D, dan E. Namun, pada penelitian ini hanya menggunakan dan berfokus pada set A, B, dan E. Pada kelas set A dan B berasal dari rekaman EEG yang dilakukan pada individu yang sehat menggunakan skema penempatan elektroda yang baku (sistem 10-20 internasional). Masing masing set tersebut terdiri dari 100 file sinyal berdurasi 23,6 detik (4096 sampel dengan frekuensi sampling 173.61 Hz). Data dari masing masing set kemudian dikumpulkan dalam direktori terpisah (A/, B/, E/), kemudian dibaca menggunakan pustaka *python* seperti *numpy* dan *pandas*. Pada penelitian ini secara singkat tahapannya terdiri dari pre-processing data, ekstraksi fitur, hingga dengan pembuatan sistem deteksi berbasis *machine learning* dengan menerapkan algoritma K-Nearest Neighbor (KNN). Berikut ini adalah penjelasan set yang diambil dalam penelitian ini yakni sebagai berikut:


- Set A: Sinyal EEG dari individu sehat dalam keadaan mata terbuka

- b. Set B: Sinyal EEG dari individu sehat dalam keadaan mata tertutup
- c. Set E: Sinyal EEG dari penderita epilepsi saat terjadi kejang




Gambar 1.Proses Perekaman EEG

Berikut ini gambar sinyal EEG Epilepsi



Gambar 2. Sinyal EEG Epilepsi

Berikut ini gambar sinyal EEG Normal



Gambar 3. Sinyal EEG Normal

3.2 Pra Pemrosesan Data

3.2.1 Segmentasi dan Normalisasi

Setiap *file* sinyal EEG berdurasi 23,6 detik (4096 sampel), kemudian bagi sinyal menjadi segmen tetap sepanjang 900 sampel dan tanpa *overlap*. Untuk mempermudah analisis dan memperbesar jumlah data pelatihan, sinyal dibagi menjadi beberapa segmen tetap sepanjang 900 sampel tanpa tumpang tindih (*non-overlapping*).

```
def segmen_sinyal(signal,segment_length=900,overlap=0):
    segments=[]
    step=segment_length-overlap
    for i in range(0,len(signal)-segment_length + 1,step):
        segments.append (signal[i:i+segment_length])
    return segments
```

3.2.2 Filter dan Transformasi

Setiap segmen kemudian difilter menggunakan *Butterworth band-pass filter* dengan batas frekuensi 0.5 Hz – 40 Hz, yang bertujuan menghilangkan *noise* frekuensi rendah dan menghilangkan *noise* frekuensi tinggi. Setelah difilter, sinyal kemudian dinormalisasi menggunakan *z-score normalization* yang bertujuan agar sinyal memiliki penyebaran data dengan nilai tengah nol dan deviasi standar satu. Untuk mengatasi gangguan ekstrem, maka nilai amplitudo sinyal dipotong (*clipping*) pada batas $\pm 500 \mu V$. Segmen yang mengandung nilai NaN atau Inf juga dihapus dengan menggunakan *z-score*.

3.2.3 Ekstraksi Fitur

Setelah tahap pra-pemrosesan, setiap segmen sinyal EEG diproses menggunakan transformasi wavelet diskrit (Discrete Wavelet Transform/DWT) dengan wavelet Daubechies 4 (db4) hingga level dekomposisi ketiga. Proses ini menghasilkan koefisien wavelet yang merepresentasikan informasi sinyal secara bersamaan dalam domain waktu dan frekuensi. Dari setiap tingkat koefisien tersebut, dihitung dua parameter statistik utama, yaitu nilai rerata (mean) dan standar deviasi.

```
import pywt
def extract_wavelet_features(signal,level=3,wavelet_nama='db4'):
```

```


coeffs=pywt.wavedec(signal,wavelet_name,level=level)
features=[]
for c in coeffs:
    features.append(np.mean(c))
    features.append(np.std(c))
return features
def extract_wavelet_features(signal,level=3,wavelet_name='db4'):
    coeffs=pywt.wavedec(signal,wavelet_name,level=level)
    features=[]
    for c in coeffs:
        features.append(np.mean(c))
        features.append(np.std(c))
    return features

```

merupakan kodingan yang digunakan Wavelet Transform untuk mengekstraksi fitur dari sinyal EEG. Transforms ini kemudian memecah sinyal menjadi beberapa komponen berdasarkan frekuensi dengan menggunakan wavelet tertentu. Program menggunakan wavelet Daubechies 4 (db4) untuk mendekomposisi sinyal menjadi beberapa level dan mengukur mean dan standard deviation dari setiap level sebagai fitur. Setelah ekstraksi fitur dengan wavelet, selanjutnya dilakukan rekonstruksi sinyal menggunakan `pywt.waverec()` dan dihitung *Mean Squared Error* (MSE) antara sinyal asli dan sinyal yang telah direkonstruksi. Data hasil ekstraksi fitur selanjutnya dipisahkan menjadi data latih dan data uji dengan memanfaatkan fungsi *train_test_split* dari pustaka *scikit-learn* dengan proporsi 80% data *train* dan 20% data *test*.

3.3 Klasifikasi Nearest Neighbor (K-NN)


Setelah fitur berhasil diekstraksi dan data dipisah dengan pembagian 80% data *train* serta 20% data *test*, tahap selanjutnya yaitu melatih dan mengevaluasi model klasifikasi dengan menggunakan algoritma K-Nearest Neighbor (KNN). K-Nearest Neighbor (K-NN) merupakan algoritma pembelajaran non parametrik yang bekerja berdasarkan jarak antar titik data. Dalam penelitian ini, model K-NN digunakan untuk melakukan klasifikasi sinyal EEG ke dalam tiga (3) kelas yaitu A (mata terbuka), B (mata tertutup), dan E (epilepsi) dengan jumlah tetangga (k): 3 sebagai parameter utama. Untuk melihat performa per kelas dapat dilihat pada gambar dibawah ini:



Gambar 4. Performa Per Kelas

merupakan plot yang digunakan untuk menunjukkan seberapa baik model KNN mengenali masing masing kelas dalam performa multikelas sinyal EEG kelas (A, B, dan E) dimana dalam plot menunjukkan bahwa model memiliki kemampuan terbaik dalam mengenali kelas B, yang ditunjukkan oleh nilai recall tertinggi. Sementara itu, kelas A dan E memiliki nilai recall yang lebih rendah, menunjukkan adanya potensi kesalahan klasifikasi (*false negative*) yang masih cukup tinggi pada kedua kelas tersebut. Secara keseluruhan, analisis recall per kelas memberikan gambaran bahwa model lebih akurat dalam mengenali kelas B, namun dengan risiko kesalahan klasifikasi yang masih cukup tinggi.

Adapun, hasil klasifikasi confusion matrix multi class dengan menggunakan algoritma KNN berdasarkan kelas A, B, dan E dapat dilihat sebagai berikut:



Gambar 5. Confusion Matrix Multi Class

mengevaluasi model untuk menilai seberapa baik kinerja model yang telah dikembangkan. Confusion matrix disajikan dalam bentuk tabel matriks yang menunjukkan kinerja model klasifikasi pada kumpulan data uji di mana nilai sebenarnya sudah diketahui. Di bawah ini adalah tabel confusion matrix yang menampilkan tiga (3) kombinasi nilai prediksi serta nilai aktual yang berbeda.

Tabel 1. Confusion Matrix Multi Class

Kelas	A	B	E
Aktual A	50 (TP)	15 (FN)	15 (FN)
Aktual B	17 (FN)	57 (TP)	6 (FN)
Aktual E	16 (FN)	13 (FN)	51 (TP)

Digunakan 3 kelas yang direpresentasikan sebagai hasil dari proses klasifikasi pada confusion matrix. Adapun tiga (3) kelas yang digunakan adalah kelas A (mata terbuka), B (mata tertutup) dan E (kejang). Dalam confusion matrix representasi dibuat kedalam sebuah istilah seperti TP, FP, FN, dan TN.

Untuk mendalami performa model secara lebih detail, dilakukan pula klasifikasi biner antara pasangan pasangan kelas tertentu. Berikut ini adalah hasil perbandingannya:

Tabel 2. Hasil Perbandingan Klasifikasi Biner

Kelas	Akurasi (%)	Waktu Testing (detik)
A vs E	77.50	0.02
A vs B	74.38	0.01
B vs E	83.12	0.01

Pengujian dari 30 sampel dari masing masing kelas. Dari tiga (3) kelas diambil 30 sampel naracoba mulai dari mata terbuka (A), mata tertutup (B) dan kejang epilepsi (E). Tiap masing masing kelas berjumlah 30 sampel dimana proporsinya yaitu 80% data train dan 20% data test. Adapun hasil dari pengujian untuk 30 sampel naracoba dapat dilihat pada tabel dibawah ini:

Tabel 3. Pengujian Data Latih dan Data Uji 30 Naracoba

Naracoba	Kelas	Jumlah Data	Dikenali (Uji)	Dikenali (Latih)
1	Mata Terbuka	30	16 (80.00%)	14 (77.78%)
2	Mata Tertutup	30	15 (98.26%)	19 (86.36%)
3	Epilepsi	30	13 (68.42%)	16 (84.21%)
Total		90	44 (80.00%)	49 (83.05%)

Setelah dilakukan pengujian terhadap 30 sampel naracoba tiap masing masing kelas, maka berdasarkan model KNN bahwasannya pada kelas mata terbuka (A) menghasilkan persentase akurasi data uji 80.00% dan 77.78% untuk data latih. Pada kelas mata tertutup (B) menghasilkan persentase akurasi data uji yaitu 98.26% dan data latih 86.236%. Sedangkan pada kelas epilepsi (E) menghasilkan persentase untuk 68.42% data uji dan 84.21% data latih. Secara keseluruhan, model KNN yang dibangun pada sistem deteksi saat ini berhasil mengenali sebagian besar data latih dengan persentase 83.05%, sementara pada data uji 80.00%.

4. KESIMPULAN

Pada sistem deteksi penyakit epilepsi yang dibangun menggunakan algoritma K- Nearest Neighbor (KNN) didapatkan hasil bahwa pada pengujian dengan menggunakan 30 naracoba didapatkan akurasi untuk data uji sebesar 80.00% dan akurasi data latih sebesar 83.05%.Sementara untuk klasifikasi biner perbandingan antar kelas A vs E, A vs B dan B vs E didapatkan akurasi terbesar pada perbandingan B vs E sebesar 83.12% yang mampu memprediksi selama waktu pengujian 0.01 detik.Model yang digunakan memiliki akurasi yang sangat baik jika diuji dari 30 sampel naracoba menggunakan model K-Nearest Neighbor (KNN) maupun pengujian perbandingan antar kelas menggunakan klasifikasi biner. Hasil akurasi pada perbandingan antar kelas menunjukkan bahwa model K-Nearest Neighbor (KNN) lebih mudah membedakan antara kondisi sehat pada mata tertutup dan kondisi epilepsi, dibandingkan membedakan antar kondisi sehat pada mata terbuka dan tertutup.

REFERENCES

- [1] Harsono, *Epilepsi: Edisi Ketiga*. Gadjah Mada University Press, 2021. [Online]. Available: https://books.google.co.id/books?id=jA_tEAAAQBAJ
- [2] N. Specchio *et al.*, "International League Against Epilepsy classification and definition of epilepsy syndromes with onset in childhood: Position paper by the ILAE Task Force on Nosology and Definitions," *Epilepsia*, vol. 63, no. 6, pp. 1398–1442, 2022, doi: 10.1111/epi.17241.
- [3] A. Novak, K. Vizjak, and M. Rakusa, "Cognitive Impairment in People with Epilepsy," *J. Clin. Med.*, vol. 11, no. 1, 2022, doi: 10.3390/jcm11010267.
- [4] WHO, "Epilepsy." [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/epilepsy>
- [5] E. Agustin and A. Eviyanti, "Detection of Epilepsy Through EEG Signals Using the DWT and Extreme Gradient Boosting Methods," pp. 1–13, 2023, [Online]. Available: <http://dx.doi.org/10.21070/ups.258>
- [6] S. Noertjahjani, "Deteksi Epilepsi Dengan Diskrit Wavelet Transform," vol. 23, pp. 304–309, 2023.

- [7] B. Y. Kerui Wu, Ziyue Zhao, “Detecting Seizures from Long Electroencephalographic Recordings,” *SeizureTransformer*, 2025, [Online]. Available: <https://arxiv.org/abs/2504.00336>
- [8] K. Ahammad, M., Sultana, S., Reza, T. A., “Real-time epileptic seizure detection using STFT and GoogleNet CNN. Heliyon,” *Heliyon*, 2024.
- [9] M. Dastgoshadeh, A., & Rabiei, “Automatic epileptic seizure detection using entropy-based features and ensemble learning,” *J. Med. Signals Sens.*, 2023.
- [10] S. P. Dewi, N. Nurwati, and E. Rahayu, “Penerapan Data Mining Untuk Prediksi Penjualan Produk Terlaris Menggunakan Metode K-Nearest Neighbor,” *Build. Informatics, Technol. Sci.*, vol. 3, no. 4, pp. 639–648, 2022, doi: 10.47065/bits.v3i4.1408.
- [11] S. N. A. Hasanah, “Ekstraksi Ciri Sinyal Eeg Untuk Gangguan Penyakit Epilepsi Menggunakan Teknik Sampling,” *J. Inform. Polinema*, vol. 5, no. 1, pp. 1–6, 2018, doi: 10.33795/jip.v5i1.127.
- [12] et al Wang, J., “A hybrid deep learning model for multiclass epileptic seizure classification using EEG data,” *Comput. Biol. Med.*, 2023.
- [13] A. ElSayed, M., Elgamal, M., & Hasanien, “Real-time epileptic seizure detection using KNN-based adaptive IoT framework,” *arXiv Prepr. arXiv*, 2023.
- [14] A. Rauf, E. Yosrita, and R. N. Aziza, “Klasifikasi Sinyal EEG Menggunakan Model K-Nearest Neighbor Untuk Pengenalan Kata Yang Dibayangkan,” *Petir*, vol. 15, no. 1, pp. 10–20, 2021, doi: 10.33322/petir.v15i1.1335.
- [15] A. Yudhana, S. Sunardi, and A. J. S. Hartanta, “Algoritma K-Nn Dengan Euclidean Distance Untuk Prediksi Hasil Penggergajian Kayu Sengon,” *Transmisi*, vol. 22, no. 4, pp. 123–129, 2020, doi: 10.14710/transmisi.22.4.123-129.
- [16] A. Eviyanti and M. A. M. Abror, “Klasifikasi Normal, Tanpa Kejang, Kejang Terhadap Sinyal Epilepsi Menggunakan Metode Teknik Sampling Dan K-Nearest Neighbor,” *SENASTER" Semin. Nas. Ris. ...*, 2020.
- [17] P. Putra, A. M. H. Pardede, and S. Syahputra, “Analisis Metode K-Nearest Neighbour (Knn) Dalam Klasifikasi Data Iris Bunga,” *J. Tek. Inform. Kaputama*, vol. 6, no. 1, pp. 297–305, 2022.
- [18] Q. A. A’yuniyah and M. Reza, “Penerapan Algoritma K-Nearest Neighbor Untuk Klasifikasi Jurusan Siswa Di Sma Negeri 15 Pekanbaru,” *Indones. J. Inform. Res. Softw. Eng.*, vol. 3, no. 1, pp. 39–45, 2023, doi: 10.57152/ijirse.v3i1.484.