

DETEKSI KONDISI FOKAL DAN NON-FOKAL PADA SINYAL EEG MENGUNAKAN WAVELET FRAKTAL

DETECTION OF FOCAL AND NON-FOCAL CONDITIONS ON EEG SIGNALS USING WAVELET FRACTAL

Pelita Santi¹, Inung Wijayanto², Raditiana Patmasari³

^{1,2,3} Universitas Telkom, Bandung

¹pelitasantii@student.telkomuniversity.ac.id, ²iwijayanto@telkomuniversity.ac.id,

³raditiana@telkomuniversity.ac.id

Abstrak

Epilepsi adalah penyakit yang disebabkan oleh aktivitas listrik di dalam otak yang tidak normal. Epilepsi ditandai dengan kelebihan jumlah listrik yang keluar dari sel-sel otak. Keadaan tersebut menyebabkan terjadinya kejang (seizure) ataupun gerakan tidak normal. Ada beberapa cara untuk melakukan deteksi kejang, salah satunya adalah dengan rekaman sinyal *electroencephalogram* (EEG). Kondisi awal dimana pasien akan didiagnosa menderita epilepsi disebut kondisi fokal. Pengenalan pola dan karakteristik sinyal EEG untuk mendeteksi kondisi fokal dengan mata telanjang membutuhkan waktu yang lama dan peluang kesalahan dalam membedakan serangan epilepsi dari kondisi normal (non-fokal) cukup besar. Oleh karena itu, sebuah sistem dapat digunakan untuk membantu ahli neurologi mendeteksi kondisi fokal dan kondisi normal pada pasien yang akan didiagnosa menderita penyakit epilepsi.

Sinyal EEG diolah dengan pengolahan sinyal digital melalui beberapa tahapan, yaitu *pre-processing*, dekomposisi, ekstraksi fitur, dan klasifikasi. Pada tahap *pre-processing* dilakukan penggabungan kanal dari dua kanal menjadi satu kanal. Selanjutnya, sinyal EEG didekomposisi menggunakan *Wavelet Packet Decomposition* (WPD). Tahap ekstraksi fitur dilakukan menggunakan analisis fraktal, yaitu Higuchi dan Katz. Kemudian, fitur tersebut diklasifikasi dengan *Support Vector Machine* (SVM) menggunakan kernel *linear* dan K-Nearest Neighbour (KNN).

Penelitian ini menggunakan *dataset* Bern Barcelona. *Dataset* tersebut merupakan rekaman sinyal EEG dari 5 pasien penderita epilepsi. Proses *pre-processing* menghasilkan satu kanal yang akan diolah pada tahap selanjutnya. Berdasarkan nilai akurasi, spesifitas dan sensitivitas didapatkan nilai tertinggi pada WPD level 3 dan 4 dengan metode Higuchi klasifikasi SVM dengan masing-masing nilai 100% dan klasifikasi KNN nilai akurasi, spesifitas dan sensitivitas didapatkan nilai tertinggi pada level 2 metode Higuchi-Katz dengan masing-masing nilai 100 %.

Kata Kunci: Epilepsi, Sinyal EEG, Fokal & Non-Fokal, WPD, SVM, KNN.

Abstract

Epilepsy is a disease caused by abnormal electrical activity in the brain. Epilepsy is characterized by an excess amount of electricity coming out of the brain cells. This condition causes seizures or abnormal movements. There are some ways to detect seizures, one of them is by the *electroencephalogram* (EEG) recordings. Epilepsy is a disease caused by abnormal electrical activity in the brain. Epilepsy is characterized by an excess amount of electricity coming out of the brain cells that causes seizures or abnormal movements. A common test for the diagnosis of epilepsy is the *electroencephalogram* (EEG). The initial condition in which a patient will be diagnosed with epilepsy is called a focal condition. Recognition of patterns and characteristics of EEG signals to detect focal conditions with the naked eye takes a long time and the chance of error in distinguishing epileptic seizures from normal (non-focal) conditions is quite large. Therefore, a system can be used to help neurologists detect focal and normal conditions in patients who will be diagnosed with epilepsy.

The EEG signal is processed by digital signal processing through several stages, namely *pre-processing*, decomposition, feature extraction, and classification. In the *pre-processing* stage, the two channels are merged into one channel. The EEG signal is decomposed using *Wavelet Packet Decomposition* (WPD). The feature extraction is carried out using fractal analysis, namely Higuchi and Katz. Then, these features are classified by *Support Vector Machine* (SVM) using *linear* kernel and K-Nearest Neighbor (KNN).

In this research uses the Bern Barcelona dataset. The dataset is a recording of EEG signals from 5 patients with epilepsy. The pre-processing process produces one channel which will be processed in the next step. Based on the value of accuracy, specificity and sensitivity, the highest value was obtained at WPD levels 3 and 4 with the Higuchi method of SVM classification with each value of 100% and the KNN classification of accuracy, specificity and sensitivity values obtained the highest value at level 2 of the Higuchi-Katz method with each value is 100%.

Keyword : Epilepsy, EEG Signals, Focal & Non-Focal, WPD, SVM, KNN.

1. Pendahuluan

Epilepsi atau biasa dikenal dengan istilah “ayan” adalah gangguan saraf yang terjadi pada otak manusia. Epilepsi ditandai dengan kelebihan jumlah listrik yang keluar dari sel-sel otak. Keadaan tersebut menyebabkan terjadinya kejang (seizure) ataupun gerakan tidak normal seperti memandang dengan tatapan kosong, atau terjadi gerakan lengan dan tungkai berulang kali.

Proses deteksi kejang dapat dilakukan dengan berbagai macam cara, salah satunya adalah dengan melihat hasil rekaman sinyal EEG yang panjang. EEG adalah sebuah tes rekaman sinyal otak dengan beberapa kanal untuk mendeteksi masalah pada pola aktivitas listrik pada otak. Pola dan karakteristik sinyal EEG pada serangan epilepsi dapat dilakukan oleh dokter ahli saraf untuk membedakan kondisi otak dalam kondisi epilepsi atau kondisi normal. Pengenalan pola dan karakteristik sinyal EEG dengan mata telanjang membutuhkan waktu yang lama dan peluang kesalahan dalam membedakan serangan epilepsi dari kondisi normal cukup besar. Oleh karena itu, dibutuhkan pengembangan proses deteksi kejang untuk mengatasi masalah tersebut. Sehingga dibutuhkan pengembangan sistem yang dapat membantu dokter ahli saraf dalam mendiagnosis serangan epilepsi secara otomatis dengan waktu dan biaya yang efektif [1].

Pada penelitian Tugas Akhir ini, melakukan deteksi kondisi fokal dan non-fokal pada sinyal EEG menggunakan dataset Bern Barcelona. Kondisi fokal pada EEG adalah rekaman sinyal EEG pada area tertentu pada otak dan terdeteksi awal adanya kejang yang dimana seseorang akan didiagnosis menderita penyakit epilepsi, sedangkan kondisi non-fokal pada EEG adalah rekaman sinyal EEG pada area otak lain yang tidak terdeteksi adanya kejang awal. Pada penelitian ini metode ekstraksi fitur yang diusulkan adalah metode analisis fraktal. Pada analisis fraktal ini dilakukan dengan metode Higuchi dan Katz. Sebelum dilakukan ekstraksi fitur, proses deteksi ini didukung dengan metode Wavelet Packet Decomposition dan klasifikasi dengan metode Support Vector Machines (SVM) dan K-Nearest Neighbour (KNN) setelahnya.

2. Dasar Teori dan Metodologi

2.1 Epilepsi

Epilepsi merupakan gangguan neurologis umum pada sistem syaraf otak manusia karena terjadinya aktivitas yang berlebihan dari sekelompok sel neuron pada otak sehingga menyebabkan berbagai reaksi pada tubuh manusia mulai dari bengong sesaat, kesemutan, gangguan kesadaran, kejang-kejang dan atau kontraksi otot. Resiko kematian lebih tinggi jika seseorang mengidap epilepsi [2].


Terdapat dua kategori dari kejang epilepsi yaitu kejang fokal (parsial) dan kejang umum. Dalam kasus epilepsi parsial, beberapa bagian otak yang terdeteksi pada sinyal EEG disebut kondisi fokal sedangkan area otak yang tidak terlibat disebut kondisi non-fokal [3]

2.2 *Electroencephalogram (EEG)*

Elektroensefalografi (EEG) adalah metode pengamatan elektrofisiologis untuk merekam aktivitas listrik dari otak yang dapat digunakan untuk mengidentifikasi penyakit. Banyak gangguan otak dapat didiagnosis oleh inspeksi visual sinyal EEG salah satunya adalah epilepsi. Para ahli dibidangnya mengedial ritme otak dalam sinyal EEG, Untuk mendeteksi sinyal, EEG mempunyai elektroda yang diletakan di area tertentu pada otak. Penelitian ini menggunakan database yang dikeluarkan oleh Bern Barcelona. Pada dataset ini diberlakukan dua kelas, yaitu kondisi fokal (F) dan nonfokal (NF). Rekaman-rekaman ini bersumber dari 5 pasien dengan sampling frekuensi 512 Hz.

2.3 *Wavelet Packet Decomposition (WPD)*

Metode WPD adalah metode dekomposisi yang mampu menganalisa sinyal EEG yang bersifat non-stasioner dan merupakan pengembangan dari dekomposisi wavelet. Berikut adalah gambar untuk WPD sampai level 2 [4].



Gambar 1. Struktur Diagram Pohon untuk WPD Level 2.

Dengan WPD, sinyal didekomposisi ke dalam komponen frekuensi rendah (*detail*) dan komponen frekuensi tinggi (*approximations*) seperti pada Gambar 1. Untuk dekomposisi level n , dihasilkan 2^n pasang yang baru. Haar, Daubechies, Symlets, Coiflets, dan Biorthogonal merupakan jenis *mother wavelet* kedalam kategori paling penting. Daubechies merupakan jenis *mother wavelet* dikenal dengan properti ortogonalitasnya yang paling efisien untuk melakukan dekomposisi karena didesain dengan tingkat keteraturan yang maksimal [4]. Pada penelitian ini menggunakan jenis *mother wavelet* Daubechies D2.

2.4 Dimensi Fraktal

2.4.1 Dimensi Fraktal Higuchi

Higuchi digunakan untuk mengkalkulasikan dimensi fraktal D yang bisa digunakan untuk mengkalkulasikan hasil pengamatan berdasarkan deret waktu 10 terbatas yang diambil secara berkala $X(1)$, $X(2)$, $X(3)$, ..., $X(N)$.

$$L(k) = \sum_{m=1}^k L_m(k) \quad (1)$$

dengan $L(k)$ adalah nilai rata rata dari panjang equasi, $L_m(k)$ adalah panjang setiap deret waktu, menunjukan waktu mulai dan N menunjukkan panjang deret waktu X

2.4.2 Dimensi Fraktal Katz

Algoritma Katz menyelesaikan permasalahan dengan pembuatan unit secara umum atau bisa disebut yardstick, dengan a adalah rata-rata antar titik yang berurutan. Algoritma Katz yang dijelaskan pada persamaan (2) menunjukkan bahwa perhitungan dilakukan langsung dari data waktu [6]

$$D = \frac{\log_{10}(n)}{\log_{10}\left(\frac{dL}{La}\right)} = \frac{\log_{10}(n)}{\log_{10}\left(\frac{d}{L}n\right)} \quad (2)$$

dengan L adalah Panjang data, n adalah Jumlah langkah pada kurva dan a menunjukkan rata-rata antar titik yang berurutan.

2.5 Cross Validation

Cross Validation (CV) adalah metode untuk memperkirakan kesalahan prediksi untuk evaluasi kinerja model. Metode statistik yang dapat digunakan untuk mengevaluasi kinerja model atau algoritma dimana data dipisahkan menjadi dua subset yaitu data pelatihan dan data uji pelatihan yang akan digunakan untuk membandingkan dengan jarak data uji dan data uji yang akan digunakan untuk proses klasifikasi pada tahap pengujian [6].

K-fold cross validation adalah salah satu proses validasi sebuah metode klasifikasi. Pada penelitian ini digunakan 10- fold cross validation dikarenakan pada penelitian sejenis tentang mendeteksi kondisi fokal dan non-fokal pada sinyal EEG juga melakukan hal yg sama.

2.6 Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan metode klasifikasi ciri yang bertujuan membangun sebuah pemisah dalam dimensi ruang tinggi yang disebut hyperplane [4]. Metode klasifikasi SVM memiliki Teknik yang canggih dapat diaplikasikan di banyak jalur [4] Dimensi-dimensi pada konversi klasifikasi *nonlinear* dalam

penggunaan fungsi kernel sedangkan klasifikasi *linear* ditingkatkan sebagai hasil [7]. Algoritma SVM Fungsi diskriminan dari SVM sendiri dapat dihitung menggunakan Persamaan (3)

$$y_i = [(w \cdot x_i) + b] - 1 \geq 0 \quad (3)$$

$y_i \in -1, +1$ sebagai identifikasi dari kategori data yang dibuat oleh SVM. Hyperplane dicari berdasarkan pengukuran margin hyperplane terhadap titik terdekat pada tiap kelas. Titik terdekat tersebut dinyatakan sebagai support vector. Metode SVM adalah mencari hyperplane terbaik sehingga didapatkannya pemisah antara dua buah kelas.


2.7 K- Nearest Neighbors

Algoritma K-Nearest Neighbors (KNN) adalah metode yang dapat digunakan untuk melakukan klasifikasi terhadap objek dengan memperhitungkan data lain yang memiliki jarak paling dekat dengan objek tersebut. Klasifikasi yang dilakukan oleh KNN ini didasarkan atas data latih yang ada dilihat dari jarak yang paling dekat dengan objek berdasarkan nilai k. fungsi jarak yang umum digunakan dalam k-NN adalah Jarak Euclidean, yang dihitung dengan menggunakan seperti pada persamaan (4)

$$D_{(a,b)} = \sqrt{\sum_{i=0}^j (a_i - b_i)^2} \quad (4)$$

Dimana nilai $D_{(a,b)}$ adalah jarak skalar dari kedua vektor a dan b dari matriks dengan ukuran d dimensi. d adalah jumlah data pada matriks. a_i adalah sampel data uji, sedangkan b_i adalah sampel data latih. k adalah variabel data atau banyaknya nilai. d adalah dimensi data. Dan $\sum$ adalah rata-rata.

2.8 Desain Sistem



Gambar 2 Diagram Blok Sistem yang Diajukan.

Berdasarkan Gambar 2, sistem dimulai dengan memasukkan data sinyal EEG yang berasal dari dataset Bern Barcelona. Dataset Bern Barcelona yang digunakan pada penelitian ini sudah melalui proses filtering dengan menggunakan BPF Butterworth dengan frekuensi 0 Hz hingga 60 Hz. Pada langkah awal akan dilakukan proses pre-processing. Pada tahap Pre-processing dilakukan proses penggabungan kanal antara dua kanal yang tersedia menjadi satu kanal. Setelah proses pre-processing, sinyal kemudian didekomposisi dengan menggunakan WPD, hasil setiap subband dari WPD kemudian di ekstrak fitur menggunakan analisis fraktal. Analisis fraktal yang digunakan pada penelitian ini yaitu dimensi fraktal Higuchi dan dimensi fraktal Katz. Keluaran dari proses ekstraksi fitur, kemudian dimasukkan kedalam klasifikasi. Pada penelitian ini, klasifikasi yang digunakan yaitu SVM dan KNN. Keluaran klasifikasi dari dihitung performansi dengan tiga parameter utama yaitu akurasi, sensitivitas dan spesifisitas.

2.9 Evaluasi Kinerja

Kinerja dari metode yang diajukan untuk deteksi kejang dievaluasi dengan nilai sensitivitas, spesifisitas dan akurasi. sensitivitas mengukur kemampuan pengujian sinyal fokal untuk menemukan hasil yang benar dari total data dengan persamaan (5) dan spesifisitas adalah pengukuran kemampuan pengujian sinyal non-fokal dari total data non-fokal menggunakan persamaan (6). akurasi adalah hasil bagi dari jumlah prediksi yang terklasifikasi secara benar dibagi total data yang diklasifikasi menggunakan persamaan (7).

$$\text{sensitivitas} = \frac{TP}{TP+FN} \times 100\% \quad (5)$$

$$\text{spesifisitas} = \frac{TN}{FP+TN} \times 100\% \quad (6)$$

$$\text{akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (7)$$

3. Pembahasan

3.1 Skenario Pengujian


Pada penelitian ini dilakukan deteksi sinyal fokal dan non-fokal EEG dengan menggunakan analisis fraktal. Skenario yang dilakukan pada penelitian ini adalah dengan mengkombinasikan penggunaan fitur Higuchi, Katz dan penggabungan Higuchi dan Katz sebagai fitur utama. Untuk proses klasifikasi digunakan dua klasifikasi yaitu dengan menggunakan SVM dan KNN.

Adapun skenario yang dilakukan adalah pada penelitian ini mengikuti pola yang ditunjukkan pada Tabel 1


Tabel 1 Skenario Pengujian

No.	Klasifikasi	Level	Metode
1.	SVM	2	Higuchi
2.			Katz
3.			Higuchi-Katz
4.		3	Higuchi
5.			Katz
6.			Higuchi-Katz
7.		4	Higuchi
8.			Katz
9.			Higuchi-Katz
10.	KNN	2	Higuchi
11.			Katz
12.			Higuchi-Katz
13.		3	Higuchi
14.			Katz
15.			Higuchi-Katz
16.		4	Higuchi
17.			Katz
18.			Higuchi-Katz

3.2 Hasil Pengujian dan Analisis Level Dekomposisi



Gambar 3 Akurasi Hasil Klasifikasi SVM



Gambar 4 Akurasi Hasil Klasifikasi KNN

Berdasarkan Gambar 3, hasil pengujian deteksi kondisi fokal dan non-fokal dengan menggunakan klasifikasi SVM dapat diambil kesimpulan bahwa nilai akurasi tertinggi didapatkan nilai tertinggi pada level 3 dekomposisi dan level 4 dekomposisi dengan ekstraksi fitur menggunakan metode Higuchi dan penggabungan metode Higuchi-Katz dengan nilai akurasi 100%. Berdasarkan Gambar 4, hasil pengujian deteksi kondisi fokal dan non-fokal dengan menggunakan klasifikasi SVM dapat diambil kesimpulan bahwa nilai akurasi tertinggi didapatkan nilai tertinggi pada level 3 dekomposisi dan level 4 dekomposisi dengan ekstraksi fitur menggunakan metode Higuchi dan penggabungan metode Higuchi-Katz dengan nilai akurasi 100%.

Berdasarkan nilai akurasi tertinggi, proses klasifikasi fokal dan non-fokal dengan menggunakan klasifikasi SVM didapatkan nilai tertinggi yaitu pada level 3 dekomposisi dan level 4 dekomposisi. Pada proses klasifikasi SVM memiliki proses mencari hyperplane terbaik, hyperplane dapat menyesuaikan karakteristik pola dari sebaran fitur, sehingga semakin besar level dekomposisi yang dapat menghasilkan frekuensi yang semakin detail dan menghasilkan lebih banyak fitur maka proses klasifikasi SVM lebih mampu menyesuaikan karakteristik pola dari sebaran fitur sehingga lebih mampu untuk melakukan proses klasifikasi lebih baik. Alasan tersebut yang membuat hasil akurasi terbaik dengan metode klasifikasi SVM pada level 3 dekomposisi dan level 4 dekomposisi.

Sedangkan berdasarkan nilai akurasi tertinggi, proses klasifikasi fokal dan non-fokal dengan menggunakan klasifikasi KNN didapatkan nilai tertinggi yaitu pada level 2 dekomposisi. Klasifikasi menggunakan metode KNN jauh lebih sederhana dibandingkan SVM. Metode klasifikasi KNN yang hanya mencari berdasarkan perbandingan komponen jarak terdekat dari satu titik kelas dengan titik kelas tetangga. Dikarenakan keterbatasan proses klasifikasi dengan KNN yang menyebabkan KNN tidak dapat maksimal untuk mengklasifikasikan sinyal EEG dengan semakin banyak fitur subband yang dihasilkan. Alasan tersebut yang membuat hasil akurasi terbaik dengan metode klasifikasi KNN pada level 2 dekomposisi.

3.3 Hasil Pengujian dan Analisis Klasifikasi SVM

Pada penelitian ini dilakukan deteksi fokal dan non-fokal pada sinyal EEG dengan analisis fraktal, yaitu Higuchi dan Katz dan proses klasifikasi deteksi fokal dan non-fokal pada sinyal EEG menggunakan klasifikasi SVM. Hasil yang diobservasi pada penelitian ini adalah nilai akurasi, sensitivitas dan spesifisitas.

Tabel 2 Hasil Klasifikasi Metode SVM

Level	Fraktal	Akurasi	Sensitivitas	Spesifitas
2	Higuchi	99.4	98.81	100
	Katz	93.8	97.82	90.41
	Higuchi-Katz	99.4	98.81	100
3	Higuchi	100	100	100
	Katz	91.2	95.98	87.32
	Higuchi-Katz	100	100	100
4	Higuchi	100	100	100
	Katz	91.4	93.67	89.35
	Higuchi-Katz	100	100	100

Berdasarkan Tabel 2 dilihat dari nilai akurasi, spesifitas dan sensitivitas didapatkan nilai tertinggi adalah level 3 dan 4 pada metode Higuchi dan penggabungan Higuchi-Katz dengan metode klasifikasi SVM didapat nilai akurasi 100%, nilai sensitivitas 100% dan spesifitas 100%.

Analisis wavelet untuk teknik estimasi spektral yang kuat untuk analisis waktu dan frekuensi sinyal karena wavelet adalah sebuah metode denoising efektif yang diperkenalkan untuk mengatasi masalah sinyal non-stasioner seperti sinyal EEG. Pada penelitian ini direkomendasikan dengan menggunakan menggunakan analisis wavelet dan proses dekomposisi transformasi paket wavelet, dikarenakan dengan dekomposisi paket wavelet bagian frekuensi tinggi yang tidak dibagi dalam analisis multiresolusi dapat didekomposisi lebih lanjut dan dapat didekomposisi sesuai dengan karakteristik sinyal yang dianalisis sehingga sesuai dengan sinyal EEG yang memiliki lima gelombang dengan rentang frekuensi yang berbeda.

Pada hasil klasifikasi menggunakan SVM dapat dilihat nilai akurasi tertinggi didapatkan pada level 3 dan level 4 dekomposisi. Semakin besar level dekomposisi maka pembagian frekuensi semakin detail, level dari frekuensi rendah sampai level frekuensi tinggi akan dibagi berdasarkan rentang frekuensi lebih sempit sehingga informasi yang terkandung pada setiap subband frekuensi dapat terjelajah dengan baik. Alasan tersebut yang membuat hasil akurasi terbaik didapatkan pada level dekomposisi 3 dan level dekomposisi 4.

3.4 Hasil Pengujian dan Analisis Klasifikasi KNN

Pada penelitian ini dilakukan deteksi fokal dan non-fokal pada sinyal EEG dengan analisis fraktal, yaitu Higuchi dan Katz dan proses klasifikasi deteksi fokal dan non-fokal pada sinyal EEG menggunakan klasifikasi KNN. Hasil yang diobservasi pada penelitian ini adalah nilai akurasi, sensitivitas dan spesifitas

Tabel 3 Hasil Klasifikasi Metode SVM

Level	Fraktal	Akurasi	Sensitivitas	Spesifitas
2	Higuchi	99.6	99.6	99.6
	Katz	89,2	88.89	89.52
	Higuchi-Katz	100	100	100
3	Higuchi	99.8	100	99.6
	Katz	86.8	87.1	86.71
	Higuchi-Katz	99.6	100	99.21
4	Higuchi	99.8	100	99.6
	Katz	82.6	81.96	83.27
	Higuchi-Katz	99.8	100	99.6

Berdasarkan Tabel 3 dilihat dari nilai akurasi, spesifitas didapatkan nilai tertinggi adalah level 2 pada metode penggabungan Higuchi-Katz dengan metode klasifikasi KNN didapat nilai akurasi 100%, nilai sensitivitas 100% dan spesifitas 100%. Pada klasifikasi KNN bahwasanya penggabungan antara metode Higuchi dan Katz membawa nilai akurasi yang baik.

Pada penelitian ini direkomendasikan dengan menggunakan menggunakan analisis wavelet dan proses dekomposisi transformasi paket wavelet, dikarenakan dengan dekomposisi paket wavelet bagian frekuensi tinggi yang tidak dibagi dalam analisis multiresolusi dapat didekomposisi lebih lanjut dan dapat didekomposisi sesuai dengan karakteristik sinyal yang dianalisis sehingga sesuai dengan sinyal EEG yang memiliki lima gelombang dengan rentang frekuensi yang berbeda.

Pada klasifikasi menggunakan KNN didapatkan level tertinggi pada level 2 dekomposisi. Proses Klasifikasi menggunakan metode KNN jauh lebih sederhana dibandingkan SVM. KNN yang hanya mencari berdasarkan perbandingan komponen jarak terdekat dari satu titik kelas dengan titik kelas tetangga. Dikarenakan keterbatasan proses klasifikasi dengan KNN yang menyebabkan KNN tidak dapat maksimal untuk mengklasifikasikan sinyal EEG dengan subband yang detail seperti ketika menggunakan proses WPD pada level yang tinggi. Berbeda dengan proses klasifikasi SVM memiliki proses mencari hyperplane terbaik, hyperplane dapat menyesuaikan karakteristik pola dari sebaran fitur.

3.5 Analisis Penggunaan Fitur Untuk Proses Klasifikasi

Pada penelitian ini dapat dilihat penggunaan proses klasifikasi Higuchi dan Katz pada klasifikasi SVM dan KNN sama-sama menghasilkan performansi yang lebih bagus. Penggunaan *Higuchi Fraktal Dimension* (HFD) memiliki kemampuan yang lebih baik dalam mereproduksi pola fraktal pada dimensi spasial yang sama ataupun pada beberapa variasi dimensi spasial, jika dibandingkan dengan Katz yang mana hanya memiliki kemampuan reproduksi pola fraktal secara general. Higuchi mempunyai kemampuan untuk menghilangkan ketergantungan komputasi pada pengukuran disetiap unit fraktal yang digunakan. Sehingga dapat dilihat dari proses klasifikasi SVM dan KNN, proses ekstraksi fitur menggunakan metode Higuchi lebih unggul dibandingkan proses ekstraksi fitur menggunakan metode Katz.

Hasil pengujian pada proses klasifikasi SVM dan KNN menggunakan penggabungan metode Higuchi dan Katz memiliki nilai akurasi yang bagus. Katz memiliki keunggulan dapat merepresentasikan rata-rata jarak diantara *successive* fraktal poin yang tidak bisa ditangani oleh fraktal Higuchi sehingga Higuchi dan Katz saling melengkapi kekurangan masing-masing sehingga Ketika kedua metode digabungkan keduanya bisa menghasilkan fitur yang lebih cocok yang bisa mengklasifikasi dua kondisi epilepsi yaitu fokal dan non-fokal. Hasil penelitian ini sejalan dengan penelitian yang dilakukan oleh Wijayanto dkk. Pada penelitian tersebut telah berhasil mengidentifikasi deteksi kondisi kejang pada sinyal EEG dengan analisis fraktal dengan hasil tertinggi yang didapatkan menggunakan dua jenis fitur yaitu penggunaan Higuchi dan Katz. Penelitian tersebut berhasil memperoleh akurasi 99.5% dalam mendeteksi kejang menggunakan penggabungan metode Higuchi dan Katz [5].

4. Kesimpulan

Dari hasil pengujian dan klasifikasi sinyal EEG kondisi fokal dan non-fokal, didapatkan kesimpulan sebagai berikut:

1. Berdasarkan proses ekstraksi fitur nilai tertinggi didapatkan pada proses ekstraksi menggunakan Higuchi dan penggabungan Higuchi-Katz pada klasifikasi SVM, sedangkan klasifikasi menggunakan metode KNN didapatkan nilai tertinggi dengan menggunakan metode penggabungan Higuchi-Katz untuk proses ekstraksi fitur.
2. Berdasarkan proses klasifikasi menggunakan SVM didapatkan nilai tertinggi berdasarkan nilai akurasi, sensitivitas, dan spesifisitas adalah dengan menggunakan dekomposisi pada level 3 dan 4 dengan nilai masing-masing 100%. Berdasarkan proses klasifikasi menggunakan KNN didapatkan nilai tertinggi berdasarkan nilai akurasi, sensitivitas, dan spesifisitas adalah dengan menggunakan dekomposisi pada level 2 dengan nilai masing-masing 100%.

REFERENSI

- [1] Y. U. Khan and J. Gotman, "Wavelet based automatic seizure detection in intracerebral electroencephalogram," *Clinical Neurophysiology*, vol. 114, no. 5, pp. 898–908, May 2003, doi: 10.1016/S1388-2457(03)00035-X.
- [2] R. Sharma, R. B. Pachori, and U. R. Acharya, "Application of entropy measures on intrinsic mode functions for the automated identification of focal electroencephalogram signals," *Entropy*, vol. 17, no. 2, pp. 669–691, 2015, doi: 10.3390/e17020669.
- [3] A. Arunkumar *et al.*, "Classification of focal and non focal EEG using entropies," *Pattern Recognition Letters*, vol. 94, pp. 112–117, 2017, doi: 10.1016/j.patrec.2017.05.007.
- [4] A. Humairani, "DETEKSI KEJANG EPILEPSI BERBASIS SINYAL EEG MENGGUNAKAN ANALISIS ENTROPI," pp. 1–8, 2020.
- [5] I. Wijayanto, R. Hartanto, and H. A. Nugroho, "Higuchi and Katz Fractal Dimension for Detecting Interictal and Ictal State in Electroencephalogram Signal," *2019 11th International Conference on Information Technology and Electrical Engineering, ICITEE 2019*, vol. 7, pp. 1–6, 2019, doi: 10.1109/ICITEED.2019.8929940.
- [6] S. S. U. HULU, "Analisis Kinerja Metode Cross Validation Dan K-Nearest Neighbor Dalam Klasifikasi Data," *Universitas Sumatera Utara*, pp. 4–16, 2020.
- [7] A. Humairani *et al.*, "Menggunakan Analisis Fraktal Epileptic Seizure Detection Based on Eeg Signals Using," pp. 1–8.