

Deteksi Kondisi Fokal Dan Non-Fokal Pada Sinyal Eeg Menggunakan Wavelet Entropi

Detection Of Focal And Non-Focal Conditions On Eeg Signals Using Wavelet Entropy

1st Idzni Ajrina Aulia
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
idzniajrinaaauliaaa@student.telkomu
niversity.ac.id

2nd Inung Wijayanto
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
iwijayanto@telkomuniversity.ac.id

Caesar Komalasari
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia
ckomalasari@telkomuniversity.ac.i
d

Abstrak

Epilepsi merupakan gangguan sistem sel saraf otak dengan pola aktivitas neuron yang berlebihan. Gejala yang pada tubuh pasien umumnya ditandai dengan adanya kejang (seizure). Proses pengenalan pola dan karakteristik sinyal EEG dengan dua kondisi EEG yaitu kondisi fokal dan non-fokal. Kondisi awal pada pasien yang belum terjadi dan belum terdiagnosis epilepsi pada rekaman sinyal EEG disebut fokal. Sedangkan, kondisi awal tidak terlihat adanya pola atau karakteristik sinyal EEG terhadap serangan epilepsi itu disebut dengan non-fokal. Kemudian, untuk proses sinyal digital dilakukan dengan empat tahapan, yaitu *preprocessing*, dekomposisi dengan WPD, ekstraksi fitur, dan klasifikasi fitur. Pada tahapan ekstraksi fitur menggunakan analisis entropi yaitu *shannon* dan *renyi*. Hasil, fitur dari ekstraksi fitur dilanjutkan ke tahap klasifikasi dengan menggunakan metode SVM dan KNN. Penelitian ini, menggunakan database *Bern Barcelona* dengan rekaman sinyal EEG 3750 pasang dataset dari 5 pasien epilepsi. Berdasarkan hasil klasifikasi fitur yang didapatkan pada level 4 memiliki nilai akurasi yang tinggi yaitu 99,86% dengan klasifikasi *shannon-renyi* menggunakan metode SVM dan K-NN. Sedangkan, spesifitas KNN 99,89%, dan sensitifitas 99,89%. Kemudian, spesifitas SVM bernilai 99,84%, sensitifitasnya 100%.

Kata Kunci: *Epilepsi, Sinyal EEG, WPD, SVM, KNN, Bern Barcelona.*

Abstract

Epilepsy is a nervous cell system disorder

characterized by abnormal neuronal activity patterns in the brain. A seizure is typically associated with symptoms in the patient's body (seizure). signals EEG with two EEG conditions, namely focal and non-focal The initial condition in a patient who has not yet developed epilepsy and has not been diagnosed with epilepsy on the EEG is referred to as focal. Meanwhile, the initial condition is known as non-focal because there is no pattern or characteristic of the EEG for epileptic seizures. The digital signal processing is then performed in four stages: preprocessing, WPD decomposition, feature extraction, and feature classification. At the feature extraction stage, Shannon and Renyi use entropy. As a result, features from the feature extraction stage are carried forward to the classification stage, where they are classified using the SVM and KNN methods. The Bern Barcelona was used in this study, along with recordings of EEG 3750 dataset pairs from 5 epilepsy patients. Based on the results of the classification of features obtained at level 4, the shannon-renyi using the SVM and K-NN methods has a high accuracy value of 99.86 percent. Meanwhile, KNN has a specificity of 99.89% and a sensitivity of 99.89%. The specificity SVM is then 99.84 percent, and the sensitivity is 100 percent.

Epilepsy, EEG Signal, WPD, SVM, KNN are some of the terms used to describe this condition.

Keywords : *Epilepsy, EEG Signals, WPD, SVM, KNN, Bern Barcelona.*

1. PENDAHULUAN

Epilepsi berawal dari gangguan sistem sel saraf otak pada pasien dan bisa menyebabkan terjadinya kejang (*seizure*).

Adanya kejang ditandai dengan kelebihan jumlah listrik yang keluar dari sel otak sehingga menyebabkan gerakan menjadi tidak normal. Keadaan tersebut mulanya berasal dari pola aktivitas sel saraf pada otak berlebihan saat pelepasan impuls listrik [1]. Pola aktivitas sel saraf pada otak dapat dilakukan dengan tes pemeriksaan *Electroencephalogram(EEG)*. *Elektroensefalogram (EEG)* merupakan rekaman sinyal pada otak



dengan menggunakan beberapa kanal dimana EEG diletakkan pada kulit kepala pasien untuk mendeteksi pola aktivitas sinyal listrik pada otak. dapat membantu para dokter ahli saraf otak untuk mendiagnosis kondisi epilepsi dari suatu karakteristik sinyal EEG.

Para dokter ahli neurologis dapat membedakan kondisi serangan epilepsi yaitu kondisi otak normal dan kondisi abnormal. Kondisi fokal yaitu kondisi awal sebelum terjadi dan terdeteksi sehingga kondisi tersebut belum dapat terdiagnosis epilepsi dengan karakteristik rekaman sinyal EEG pada area otak tertentu. Sebaliknya, kondisi non-fokal merupakan kondisi awal rekaman sinyal EEG pada area otak lain dan tidak dapat terdeteksi kalau adanya kejang. Berdasarkan kasus kejang (*seizure*) kebanyakan penderita pada anak-anak usia kurang dari 15 tahun [2]. Berbeda dengan kasus kejang non-epilepsi dengan disebabkan oleh stress atau masalah gangguan psikologis [3].

Pada penelitian Tugas Akhir ini, dilakukan deteksi serangan epilepsi dilakukan terhadap dataset *Bern- Barcelona*. Dataset tersebut terdiri dari 5 pasien rekaman sinyal EEG. Selama proses penelitian, menggunakan metode analisis *entropi* untuk melakukan ekstrasi fitur. Hasil tersebut akan membentuk sebuah fitur fokal dan non-fokal. Penelitian ini, sebelum melakukan ekstrasi fitur ada proses langkah pendukung deteksi serangan epilepsi yaitu dekomposisi dengan *WPD(Wavelet Packet Decomposition)* menggunakan metode *SVM* dan *KNN*. Langkah terakhir adalah tahap proses klasifikasi sinyal pada fokal dan non-fokal dengan metode klasifikasi *SVM (Support Vector Machines)* dan *KNN (K-Nearest Neighbour)*.

2. DASAR TEORI DAN METODOLOGI

2.1 EPILEPSI

Dari lima puluh juta kasus epilepsi yang terkena pada masyarakat mencapai 8,2% dari lima puluh per seratus ribu penduduk [4]. Epilepsi merupakan gangguan sel saraf pada otak yang bisa saja terjadi secara berulang-ulang. Pemicu gangguan tersebut berasal dari aktivitas neuron yang berlebihan. Umumnya, secara kasat mata gejala awal epilepsi adalah adanya kejang-kejang pada tubuh pasien. Dimana, adanya impuls sel saraf pada otak melepaskan neuron agar bisa membawa pesan sinyal ke sel tubuh yang akan menjadi sasarannya [5].

Dalam kasus penelitian ini terdapat dua kategori keadaan kejang diantaranya fokal dan non-fokal. Tetapi, para dokter ahli saraf otak belum menemukan caranya untuk penyembuhan secara total terhadap epilepsi. Jika pasien

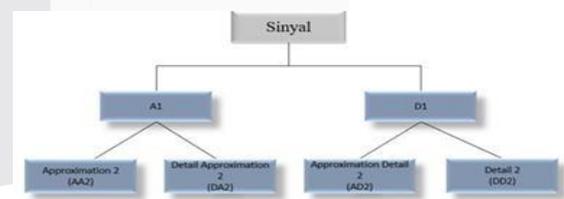
semakin parah maka diharuskan dilakukan tindakan operasi. Jadi, tidak dapat dinyatakan bahwa kondisi fokal dan non-fokal itu sama dengan kondisi ictal pada epilepsi.

2.2 ELECTROENCEPHALOGRAM (EEG)

Elektroensefalografi (EEG) adalah metode perekam aktivitas listrik yang dihasilkan dari sel-sel saraf otak secara spontan untuk mengidentifikasi suatu penyakit. Diantaranya yang dapat di diagnosis oleh EEG adalah epilepsi. Kondisi yang mempengaruhi sinyal EEG disebabkan dari beberapa variabel. Salah satunya adalah kondisi kesehatan mental, umur pasien, dan lain-lain. Para dokter ahli saraf otak melakukan proses deteksi sinyal EEG secara real time. Dataset yang digunakan dalam kasus ini yaitu dataset *Bern Barcelona*. Dataset tersebut berisikan 3750 rekaman sinyal EEG dari dua macam kondisi pasien yaitu fokal dan non-fokal dengan menggunakan frekuensi sampling sebesar 512 Hz.

2.3 WAVELET PACKET DECOMPOSITION (WPD)

Metode WPD adalah metode dekomposisi sinyal yang mampu menganalisa sinyal EEG yang bersifat non-stasioner. WPD bekerja berdasarkan transformasi sinyal hingga ke level yang ditentukan dari domain waktu ke domain frekuensi. Dimana, domain frekuensi dapat dilakukan berdasarkan frekuensi high pass filter dan menghasilkan subband yang lebih banyak lagi dengan resolusi tinggi. Dengan ini, dapat dilakukan pengembangan dekomposisi WPD yang menggunakan struktur komponen frekuensi diagram pohon WPD level 2.



Gambar 1. Struktur Diagram Pohon untuk WPD Level 2.

Dengan perubahan sinyal menggunakan WPD, terdapat berbagai macam jenis wavelet. Tetapi, pada kasus ini menggunakan jenis *mother wavelet* daubechies 2 (db2). Dimana, pada proses dekomposisi sinyal memiliki bagian komponen sinyalnya berdasarkan tingkat keteraturan koefisien secara maksimal. Proses sinyal input termasuk membentuk ke dalam komponen frekuensi rendah (*detail*) dan komponen frekuensi tinggi (*approximations*). Kemudian, A1 sebagai pendekatan koefisien sinyal dan frekuensi tinggi. Selain itu, tingkatan level juga dapat ditentukan dari kasus yang ingin dicari. Dengan menggunakan dekomposisi level n . Yang artinya, dapat dihasilkan dari 2^n pasang yang baru. uga dapat ditentukan Untuk dekomposisi level n , dihasilkan 2^n pasang yang

$$H(x) = - \sum_{i=0}^{N-1} P \log (P(x))$$

Dimana :

$P(x)$ = Probabilitas

P_i = Proporsi

N = Jumlah Partisi

$H(x)$ = Himpunan n kasus entropi

Ketika variabel sinyal diskrit tidak beraturan maka $x = [x(0), x(1), x(N-1)]$, dimana sinyal diskrit $p(x)$ ditransformasikan sebagai distribusi probabilitas. Dan ditunjukkan untuk penempatan diskrit.

2.4.1 SHANNON ENTROPI

$$ShEN = \sum_{i=1}^n P(x_i) \log \frac{1}{P(x_i)}$$

Dengan nilai $P(x_i)$ merupakan peluang terjadinya x_i dan $b > 1$. Karena, semakin tinggi nilai entropi makasemakim kompleks dan tidak pasti hasilnya. Dan tentu saja semakin sulit untuk dideteksi.

$$REN(\alpha) = \frac{1}{1-\alpha} \sum p_i^\alpha$$

$\alpha \neq 1$ dan p_i merupakan total daya spektral. Jika, $\alpha \geq 2$ maka entropi menjadi lebih halus dan batas bawah lebih rendah. Sedangkan, $\alpha = 1$ Shannon menghasilkan jumlah permukaan halus dari smooth entropi. Kelebihan dari Renyi adalah saat pengubahan ukuran variabel-variabelnya, nilai entropi berubah secara konstan tetapi tidak mempengaruhi fungsi kerapatan yang digunakan [7].

2.5 CROSS VALIDATION

Cross Validation (CV) adalah metode yang memprediksi kinerja model. Metode ini membagi data menjadi dua bagian untuk evaluasi

baru. Oleh karena itu, daubechies 2 dapat melakukan proses didekomposisi berdasarkan tingkat keteraturannya secara maksimal.

2.4 ENTROPI

Entropi merupakan metode analisis jenis data dengan mentransformasikan sinyal domain waktu secara berurutan dan diukur berdasarkan kompleksitas sinyal *EEG*. Tujuan dari entropi yaitu memiliki kemampuan untuk mengekstrak informasi yang terdapat dalam sebuah sinyal. Sementara itu, *entropi* mempunyai kemampuan untuk melihat nilai ketidakteraturan dan nilai ketidak teraturan dan nilai kandungan informasi didalamnya. *Entropi* dapat didefinisikan sebagai berikut [13] :

$$H(x) = - \sum_{i=0}^{N-1} P_i \log (P_i) \quad (1)$$

Shannon *entropi* bertujuan untuk mengukur kompleksitas sinyal melalui time frequency representation. Shannon *entropi* dapat melakukan tahapan kompresi dengan sejumlah bit tergantung berdasarkan dari ukuran besar kecilnya informasi [6].

$$ShEN = \sum_{i=1}^n P(x_i) \log \frac{1}{P(x_i)} \quad (2)$$

2.4.2 RENYI ENTROPI

Renyi entropi bertujuan untuk membuat perhitungan kompleksitas sinyal EEG di domain waktu dan memiliki kelebihan yaitu adanya perubahan ukuran pada variabelnya.

$$REN(\alpha) = \frac{1}{1-\alpha} \sum p_i^\alpha \quad (3)$$

kinerja model. Dimana, datanya akan menjadi dua bagian yaitu data pelatihan sebagai membandingkan jarak data uji klasifikasi dan data uji yang digunakan untuk proses klasifikasi ke tahap pengujian. K-fold cross validation merupakan metode validasi data sinyal EEG untuk melakukan proses suatu klasifikasi.

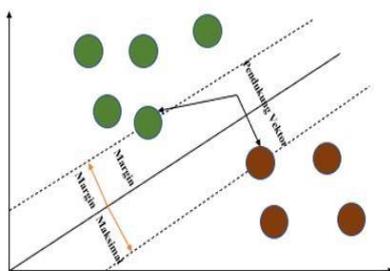
Pada penelitian ini, menggunakan 10-fold cross validation untuk mendeteksi suatu kondisi fokal dan non- fokal pada sinyal EEG. Sehingga, data tersebut terdapat 10 data yang terdiri dari 10 subset untuk melakukan proses cross validation. Tetapi, hanya menggunakan 9 data saja sebagai data pelatihan dan 1 data dilakukan untuk sebuah pengujian data.

2.6 SUPPORT VECTOR MACHINE (SVM)

Support Vector Machine (SVM) merupakan metode klasifikasi ciri yang bertujuan dan membangun sebuah pemisah dalam dimensi ruang tinggi yang disebut hyperplane. Tujuan dari SVM yaitu untuk mencari hyperlane dalam sebuah N, dimana N merupakan jumlah fitur pada data yang dapat mengklasifikasikan data yang akan diuji [8]. Upaya untuk menemukan *hyperlane* sebagai pemisah terbaik antar kedua kelas didapatkan dengan cara mengukur *hyperlane* tersebut dan mencari titik maksimum. Sehingga, margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya. Fungsi diskriminan dari SVM sendiri dapat dihitung menggunakan persamaan dibawah ini :

x_1

x_i didefinisikan sebagai data input y_i sebagai identifikasi data yang dibuat oleh SVM. Dimana, keluaran x_i , w , b termasuk parameter nilainya. Hyperplane yang dimaksud adalah batas terjadinya klasifikasi data yang diujikan untuk dicari berdasarkan dari titik jarak yang bergantung dari jumlah fitur terdekat. Metode SVM adalah mencari hyperplane terbaik sehingga didapatkannya pemisah antara dua buah kelas.



Gambar 2. Ilustrasi Hyperlane Maksimal.

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. Klasifikasi yang dilakukan oleh KNN ini didasarkan atas data latih yang ada dilihat dari jarak yang paling dekat dengan objek berdasarkan nilai k . Dan fungsi jarak KNN termasuk perhitungan jarak titik-titik pada grafik yang disebut jarak Euclidean. Jarak Euclidean dapat dihitung dengan menggunakan persamaan sebagai berikut :

$$D(x_1, x_2) = \sqrt{\sum^N (x_1) - (x_2)^2}$$

Dimana nilai (x_1, x_2) adalah jarak skalar dari kedua vektor a dan b dari matriks dengan ukuran d dimensi. d adalah jumlah data pada matriks. x_1 adalah sampel data uji, sedangkan x_2 adalah sampel data latih. k adalah variabel data atau banyaknya nilai. d adalah dimensi data. Dan \sum adalah rata-rata.

Keterangan :

$D(x_1, x_2)$ = Jarak

skalar dari kedua

vektor 1 dan 2 dari

matriks berukuran d

dimensi $D =$

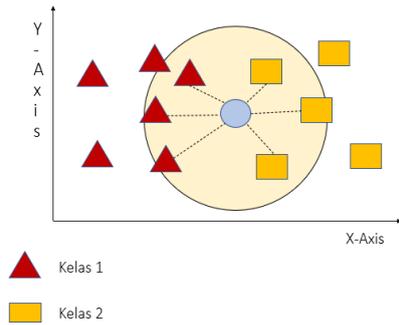
Jumlah data matriks

= Sampel data uji

(4)

$i = 1$
 i
 i

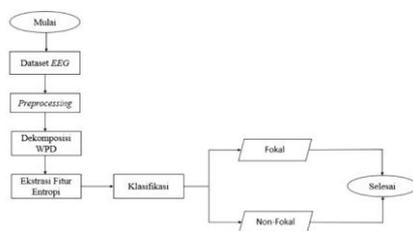
x_2 = Sampel data latih



Gambar 3. Ilustrasi Metode Klasifikasi KNN.

kondisi yang berbeda. Pertama, dalam kondisi fokal. Yang, kedua dalam kondisi non-fokal. Dimana, dataset tersebut berisikan rekaman sinyal EEG dari 5 pasien penderita fokal dan non-fokal. Dan jumlah total dataset EEG yang digunakan sebanyak 3750 rekaman sinyal fokal dan 3750 rekaman sinyal non-fokal. Dengan, menggunakan frekuensi sampling sebesar 512 Hz.

2.8 DESAIN SISTEM



Gambar 4. Diagram Blok Sistem yang Diajukan.

Berdasarkan Gambar 4, 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. Filtering tersebut dapat mengurangi noise terhadap kanal yang akan ditunjukkan dengan meloloskan frekuensi yang dibutuhkan. Selanjutnya, dilakukan proses pre-processing. Pada tahap pre-processing dilakukan untuk memproses sinyal EEG yang dihasilkan sebagai keluaran penggabungan kedua sinyal menjadi satu kanal. Kemudian, setelah pre-processing dilakukan proses didekomposisi dengan menggunakan WPD. Dimana, hasil setiap subband dari WPD berdasarkan tingkatan levelnya. Setelah itu, sinyal di ekstrak fitur menggunakan analisis entropi. Metode analisis entropi yang digunakan pada kasus ini adalah Shannon dan Renyi. Dan hasil keluaran dari proses ekstraksi fitur, akan dimasukkan kedalam proses klasifikasi kondisi fokal dan non-fokal. Pada penelitian ini, klasifikasi yang digunakan yaitu SVM dan KNN. Sehingga, keluaran klasifikasinya dapat dihitung berdasarkan performansi dengan tiga parameter utama yaitu akurasi, sensitivitas dan spesifitas.

2.9 DATASET EEG

Dataset EEG yang digunakan berasal dari Bern Barcelona. Penelitian ini, terdapat dua

2.10 EKSTRAKSI FITUR DENGAN MENGGUNAKAN ANALISIS ENTROPI

Ekstraksi fitur dapat membedakan ciri dari satu kelas dengan kelas lainnya. Pada sinyal EEG digunakan tahap proses ekstraksi fitur untuk mendukung pencapaian nilai akurasi maksimal. Konsep *entropi* sendiri dilakukan di setiap kanal dan *window* secara satu per satu. Untuk perhitungan *entropi* dari sebuah sinyal EEG dalam penelitian ini yaitu *shannon* dan *renyi*. Sedangkan, keluaran yang diperoleh dari ekstraksi fitur akan dilakukan ke tahap proses klasifikasi pada kondisi fokal dan non-fokal.

2.11 EVALUASI KERJA

Metode kinerja ini digunakan untuk mendeteksi kejang berdasarkan performansi sistem yang telah dibuat. Kemudian, dievaluasi dengan mencari total dataset dari nilai akurasi, spesitifitas, dan sensitifitas. Sedangkan, untuk mengetahui kemampuan sistemnya berhasil atau tidak dapat dilakukan sesuai dengan persamaan pengujian(6), (7), (8).

$$= \frac{TN}{F + P + T} \times 100\% \quad (7)$$

$$\times 100\% \quad (8)$$

No.	Metode Klasifikasi	Level	Metode Fitur
1	KNN	2	Shannon
			Renyi
			Shannon-Renyi
2	KNN	3	Shannon
			Renyi
			Shannon-Renyi
3	KNN	4	Shannon
			Renyi
			Shannon-Renyi

3 HASIL DAN PEMBAHASAN

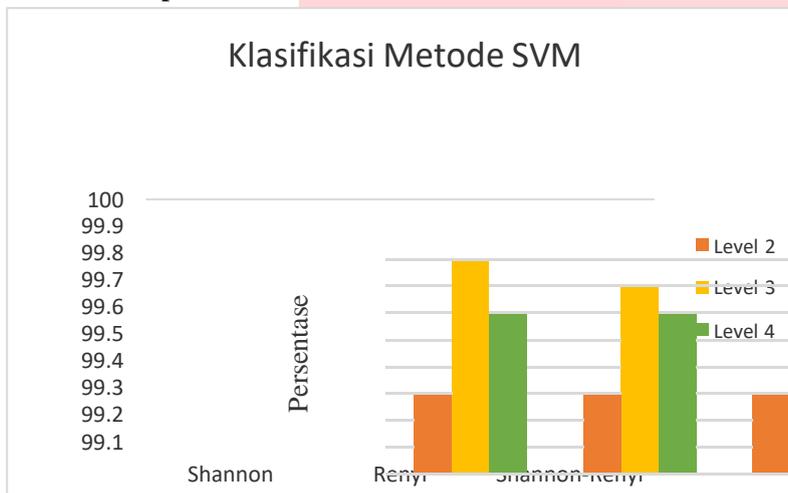
3.1 Skenario Pengujian

Pada penelitian ini dilakukan deteksi sinyal fokal dan non-fokal EEG terhadap penggunaan ekstraksi fitur dengan menggunakan analisis *entropi*. Skenario yang dilakukan pada penelitian ini adalah dengan penggunaan fitur *shannon*, *renyi* dan penggabungan dari *shannon-renyi*. Proses klasifikasi digunakan dua klasifikasi yaitu dengan menggunakan SVM dan KNN. Adapun skenario tabel 1 yang dilakukan pada penelitian ini sebagai berikut :

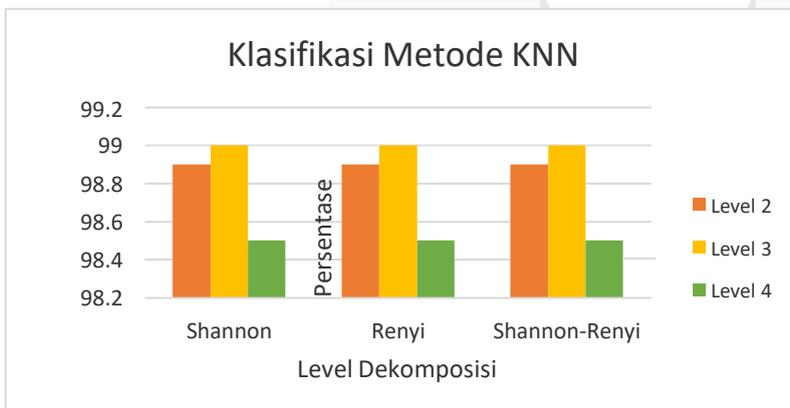
Tabel 1 Skenario Pengujian

4.	SVM	2	Shannon
			Renyi
			Shannon-Renyi
5.	SVM	3	Shannon
			Renyi
			Shannon-Renyi
6.	SVM	4	Shannon
			Renyi
			Shannon-Renyi

3.2 Hasil Pengujian dan Analisis Level Dekomposisi



Gambar 5.



Gambar 6. Akurasi Hasil Klasifikasi KNN

Berdasarkan Gambar 5, 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 menggunakan metode penggabungan *shannon* dan *renyi* dengan nilai akurasi 99,9%. Berdasarkan Gambar 6, hasil

pengujian deteksi kondisi fokal dan non-fokal dengan menggunakan klasifikasi *KNN* dapat diambil kesimpulan bahwa nilai akurasi tertinggi didapatkan nilai tertinggi pada level 3 dekomposisi penggabungan *shannon* dan *renyi* dengan nilai 99,0%.

Proses klasifikasi *SVM* menyesuaikan berdasarkan karakteristik jarak fitur yang ada dan dapat membagi komponen sinyal menjadi bentuk frekuensi tinggi dan frekuensi rendah. Sehingga, hasil dekomposisi menggunakan *SVM* memiliki proses pencarian hyperplane terbaik. Alasan tersebut, menunjukkan bahwa *SVM* lebih unggul dan lebih mampu menghasilkan nilai keakurasiannya secara baik.

Sedangkan berdasarkan nilai akurasi tertinggi, proses klasifikasi fokal dan non-fokal dengan menggunakan klasifikasi *KNN* didapatkan nilai tertinggi yaitu pada level 3 dekomposisi menggunakan metode penggabungan *shannon* dan *renyi*. Klasifikasi menggunakan metode *KNN* lebih praktis dibandingkan *SVM*. Metode klasifikasi *KNN* yang hanya mencari objek dengan memperhitungkan data lain yang memiliki jarak paling terdekat dengan objek. Atau bisa juga berdasarkan perbandingan dari satu titik kelas dengan titik kelas tetangga. Dikarenakan keterbatasan proses klasifikasi dengan *KNN* adanya pengaruh nilai *k* terhadap pengklasifikasian sinyal yang menghasilkan banyaknya fitur subband. Dari alasan tersebut dapat disimpulkan bahwa *KNN* bisa menyebabkan hasil nilai akurasi dekomposisi *KNN* secara tidak maksimal.

3.3 Hasil Pengujian dan Analisis Klasifikasi SVM

Pada penelitian ini dilakukan deteksi fokal dan non-fokal pada sinyal *EEG* dengan analisis entropi, diantaranya *shannon* dan *renyi*. Dilakukan berdasarkan proses klasifikasi deteksi fokal dan non-fokal pada sinyal *EEG* menggunakan metode klasifikasi *SVM* dengan dilakukan perhitungan nilai berdasarkan observasi performansi yang sudah ditentukan.

Tabel 2 Hasil Klasifikasi Metode *SVM*

Level	Entropi	Akurasi	Spesitifitas	Sensitivitas
2	Shannon	99,34%	99,30%	99,38%
	Renyi	99,32%	99,25%	99,38%
	Shannon-Renyi	99,32%	99,22%	99,41%
3	Shannon	99,85%	99,84%	99,84%
	Renyi	99,85%	99,81%	99,89%
	Shannon-Renyi	99,86%	99,86%	100%
	Shannon	99,76%	99,52%	100%

4	Renyi	99,74%
	Shannon-Renyi	99,77%

Berdasarkan Tabel 2 dilihat dari nilai akurasi, spesitifitas dan sensitivitas didapatkan nilai tertinggi adalah level 3 pada metode penggabungan *shannon-renyi* dengan metode klasifikasi *SVM*. Didapatkan nilai akurasi 99,86%, nilai sensitivitas 99,86% dan spesitifitas 100%.

Diawali dengan karakteristik gelombang sinyal *EEG* yang memiliki lima gelombang sinyal berdasarkan frekuensi aktivitas pada otak berbeda-beda. Sehingga, pada penelitian ini merepresentasikan kemunculan gelombang kanal 1 dan gelombang kanal 2 dengan proses dekomposisi transformasi wavelet. Transformasi memungkinkan digunakan untuk multi resolusi yang didekomposisi dengan *WPD* pada sub-subsinyalnya. Dan dilanjutkan proses analisis yang dilakukan menggunakan analisis wavelet. Oleh karena itu, proses hasil klasifikasi menggunakan metode *SVM* ini terlihat bahwa semakin besar level dekomposisi maka pembagian frekuensinya semakin kompleks, dan rentang frekuensinya juga semakin sempit.

Pada hasil klasifikasi menggunakan *SVM* yang telah dilakukan hal diutamakan dalam pencarian permasalahan ini adalah menentukan nilai akurasi maksimal. Dapat dilihat bahwa dari nilai akurasi tertinggi didapatkan pada level 3 dekomposisi. Pada proses level dekomposisi, jika semakin besar tingkat levelnya maka pembagian frekuensi tinggi sampai frekuensi rendah dan semakin kecil *subband* frekuensi yang terdeteksi dengan baik.

3.4 Hasil Pengujian dan Analisis Klasifikasi KNN

Pada penelitian ini dilakukan deteksi fokal dan non-fokal pada sinyal EEG dengan analisis entropi, yaitu *shannon* dan *renyi*. Kemudian, proses klasifikasi deteksi fokal dan non-fokal pada sinyal EEG menggunakan klasifikasi KNN. Hasil yang telah ditinjau selama penelitian ini adalah berdasarkan dari nilai akurasi, sensitivitas dan spesitifitas.

KNN dapat disimpulkan bahwa level dengan nilai tertinggi adalah level 3 dekomposisi. Dapat dilihat antara proses klasifikasi menggunakan metode SVM lebih unggul dibandingkan proses klasifikasi menggunakan metode KNN. Walaupun, klasifikasi metode KNN jauh lebih sederhana dibandingkan SVM. Cara kerja klasifikasi metode KNN berdasarkan komponen jarak terdekat dari satu kelas dengan titik kelas tetangganya. Dengan ini, SVM dapat menyesuaikan karakteristik pola fitur berdasarkan proses pencarian hyperlane.

Tabel 3 Hasil Klasifikasi Metode KNN

Level	Entropi	Akurasi	Spesitifitas	Sensitivitas
2	Shannon	98,57%	98,35%	98,79%
	Renyi	99,86%	99,45%	99,06%
	Shannon-Renyi	98,49%	98,27%	98,71%
3	Shannon	98,82%	99,33%	98,28%
	Renyi	98,84%	98,23%	99,45%
	Shannon-Renyi	99,86%	99,89%	99,89%
4	Shannon	97,60%	95,67%	99,69%
	Renyi	97,69%	95,86%	99,66%
	Shannon-Renyi	97,61%	95,77%	99,61%

Berdasarkan Tabel 3 dilihat dari nilai akurasi, spesitifitas dan sensitivitas didapatkan nilai tertinggi adalah level 3 pada metode penggabungan *shannon-renyi* dengan metode klasifikasi SVM. Yang, didapat pada nilai akurasi 99,86%, nilai sensitivitas 99,89% dan spesitifitas 99,81%. Pada level 3 dengan metode penggabungan *shannon-renyi* merupakan nilai akurasi yang maksimal.

Penelitian ini menggunakan proses *preprocessing*. Kemudian, di proses lebih lanjut ke perubahan sinyal EEG atau dekomposisi wavelet dengan WPD yang membagi menjadi dua frekuensi tinggi dan frekuensi rendah. Sedangkan, proses dekomposisi untuk mengidentifikasi tingkat keakurasian kondisi fokal dan non-fokal. Menggunakan frekuensi sampling yang digunakan adalah 512 Hz. Untuk, setiap rekaman sinyal EEG memiliki durasi waktu sekitar 20 per detik per rekaman. Hal tersebut membuat komputasi terhadap pola karakteristiknya menjadi sangat rendah. Sedangkan, *shannon entropi* memiliki komputasi nilai terhadap proses pengerjaannya relatif cepat. Jika semakin tinggi nilai *entropi* maka semakin kompleks tidak menentu bahkan semakin lebih sulit untuk terdeteksinya. Jadi, kedua metode tersebut sama-sama memiliki kecocokan sistem satu sama lain jika diantara salah satunya tidak mampu merepresentasikan jarak secara maksimal maka penggabungan metode *shannon* dan *renyi entropi* saling melengkapi satu sama lain.

Selanjutnya, pada klasifikasi menggunakan

4 KESIMPULAN
 Dari hasil pengujian dan klasifikasi sinyal EEG kondisi fokal dan non-fokal, didapatkan kesimpulan sebagai berikut:
 1. Hasil terbaik proses klasifikasi kondisi fokal dan non-fokal pada sinyal EEG diperoleh dengan menggunakan metode akurasi fitur *shannon* dan *renyi entropi* secara bersamaan, serta metode klasifikasi menggunakan SVM. Kemudian, nilai akurasi terbaik yang diperoleh adalah 99,9%. Sementara itu, penggunaan metode KNN untuk proses klasifikasi diperoleh hasil akurasi terbaik sebesar 90%.

2. Proses klasifikasi fitur menggunakan SVM dan KNN menghasilkan nilai terbaik berdasarkan nilai akurasi, spesitifitas dan sensitivitas. Untuk pengujian sistem klasifikasi dengan SVM didapatkan pada level 3 dekomposisi dengan metode penggabungan *shannon* dan *renyi* dimana nilai akurasi maksimal

adalah 99,86%, spesifisitas 99,86% dan sensitivitas 100%. Kemudian, untuk pengujian sistem klasifikasi *KNN* didapatkan pada level 3 dekomposisi dengan metode penggabungan *shannon-renyi* dengan nilai akurasi maksimal yaitu 99,86%, spesifisitas 99,89%, sensitivitas 99,89%.

diagnosis of epilepsy using EEG signals: A review,” *Knowledge-Based Syst.*, vol. 88, pp. 85–96, 2015, doi: 10.1016/j.knsys.2015.08.004.

- [8] L. Y. Napitupulu, N. Suciati, and D. A. Navastara, “Implementasi deteksi serangan epilepsi dari data rekaman EEG menggunakan Weighted Permutation Entropy dan Support Vector Machine.,” *J. Tek. ITS*, vol. 6, no. 2, 2017, doi: 10.12962/j23373539.v6i2.23796.

REFERENSI

- [1] A. Damayanti, A. B. Pratiwi, and Miswanto, “Epilepsy detection on EEG data using backpropagation, firefly algorithm and simulated annealing,” *Proc. - 2016 2nd Int. Conf. Sci. Technol. ICST 2016*, pp. 167–171, 2017, doi: 10.1109/ICSTC.2016.7877368.
- [2] K. Khairin, L. Zeffira, and R. Malik, “Karakteristik Penderita Epilepsi di Bangsal Anak RSUP Dr. M. Djamil Padang Tahun 2018,” *Heal. Med. J.*, vol. 2, no. 2, pp. 16–26, 2020, doi: 10.33854/heme.v2i2.453.
- [3] C. Ganda, “Kejadian epilepsi pada anak dengan riwayat kejang demam pada tahun 2014-2019 : studi literatur,” p. 84, 2021.
- [4] D. E. G. M L Perlis , E L Kehr, M T Smith, P J Andrews, H Orff, “TEMPORAL AND STAGEWISE DISTRIBUTION OF HIGH FREQUENCY EEG AND ACTIVITY IN PATIENTS WITH PRIMARY AND SECONDARY INSOMNIA AND IN GOOD SLEEPER CONTROLS,” *TEMPORAL STAGEWISE Distrib. HIGH Freq. EEG Act. PATIENTS WITH Prim. Second. INSOMNIA GOOD SLEEPER Control.*, 2001.
- [5] Izzati Shoba Maryam, I. A. S. Wijayanti, and K. Tini, “Karakteristik Klinis Pasien Epilepsi di Poliklinik Saraf Rumah Sakit Umum Pusat Sanglah Periode Januari - Desember 2016,” *Karakteristik Klin. Pasien Epilepsi di Poliklin. Saraf Rumah Sakit Umum Pus. Sanglah Periode Januari - Desember 2016*, 2018.
- [6] A. Moukadem, A. Dieterlen, and C. Brandt, “Shannon Entropy based on the S-Transform Spectrogram applied on the classification of heart sounds,” *ICASSP, IEEE Int. Conf. Acoust. Speech Signal Process.* - *Proc.*, no. January 2015, pp. 704–708, 2013, doi: 10.1109/ICASSP.2013.6637739.
- [7] U. R. Acharya, H. Fujita, V. K. Sudarshan, S. Bhat, and J. E. W. Koh, “Application of entropies for automated