Terbit *online* pada laman web jurnal :
http://ejournal.amikompurwokerto.ac.id/index.php/telematika/

Telematika

Accreditated SINTA "2" Kemenristek/BRIN, No. 85/M/KPT/2020

Peningkatan Ekstrasi Ciri Sinyal Epilepsi Menggunakan Teknik Sampling

Ade Eviyanti[1], Hindarto[2], M. Abror[3]

[1,2]Program Studi Informatika, Fakultas Sains dan Teknologi
[3]Program Studi Agro Teknologi, Fakultas Sains dan Teknologi
Universitas Muhammadiyah Sidoarjo
Email : adeeviyanti@umsida.ac.id[1], hindarto@umsida.ac.id[2], abror@umsida.ac.id[3]

ARTICLE INFO

Article History:
Received June 6, 2020
Revised June 21, 2020
Received August 22, 2020
Online August 31, 2020

Keywords:
Epilepsy signal
Sampling technique
KNN

ABSTRACT

Epilepsy is a brain disorder characterized by repeated seizures. Epileptic seizures are episodes that can vary from short periods to long periods and are almost undetectable. Electroencephalography (EEG) is a way to record the activities of the human brain. EEG is a brain sensor that can be used to determine epilepsy. The purpose of this study is to classify the signals of people who have epilepsy disease and the signals of people in good health. The method used is a sampling technique method to find the characteristics of EEG signals and the K-Nearest Neighbor (KNN) method to find the classification of EEG signals. The data used is EEG signal data consisting of five data sets (data set A, data set B, data set C, data set D, and data set E), this data comes from public data. Each data set contains 100 EEG signal data on one EEG sensor channel. This study only uses two classes, the first is Data Set A and the second is Data Set E. Data Set A is a person in normal condition, and data set E is a person in a state of having epilepsy. In the sampling technique process, the values taken are the average value and the standard deviation value. Research that has been done yields an accuracy rate of 100%.

Kata Kunci:
Sinyal Epilepsi
Teknik sampling
K-NN

ABSTRAK

Epilepsi adalah gangguan otak yang ditandai dengan kejang berulang ulang. Kejang epilepsi adalah episode yang dapat bervariasi dari periode singkat hingga periode lama dan hampir tidak terdeteksi. Electroencephalography (EEG) adalah cara untuk merekam aktifitas otak manusia. EEG merupakan suatu sensor otak yang dapat digunakan untuk mengetahui penyakit epilepsi. Tujuan dari penelitian ini adalah mengklasifikasikan sinyal orang yang mempunyai penyakit eplepsi dan sinyal orang dalam kondisi sehat. Metode yang digunakan adalah metode teknik sampling untuk mencari ciri dari sinyal EEG dan metode K-Nearest Neighbor (KNN) untuk mencari klasifikasi dari sinyal EEG. Data yang digunakan adalah data sinyal EEG yang terdiri dari lima set data(data set A, data set B, data set C, data set D dan data set E), data ini berasal dari data publik. Setiap data set berisi 100 data sinyal EEG pada satu channel sensor EEG. Penelitian ini hanya menggunakan dua kelas yaitu pertama adalah data Set A dan kedua adalah data Set E. Data Set A adalah Orang dalam keadaan normal dan data Set E adalah orang dalam keadaan mempunyai penyakit Epilepsi. Pada proses teknik sampling nilai yang diambil adalah nilai rata-rata dan nilai standart deviasi. Penelitian yang telah dilakukan menghasilkan tingkat akurasi sebesar 100%.

Correspondence:
Telepon: +62 75263863
E-mail:
hindarto@umsida.ac.id

PENDAHULUAN

Epilepsi adalah gangguan otak yang ditandai dengan kejang berulang ulang. Kejang epilepsi adalah episode yang dapat bervariasi dari periode singkat hingga periode lama dengan goncangan yang keras dan hampir tidak terdeteksi (Diker *et al.*, 2018). Episode ini dapat menyebabkan cedera fisik,

termasuk tulang yang kadang-kadang patah. Pada epilepsi, peristiwa kejang memiliki kecenderungan untuk kambuh dan tidak memiliki penyebab langsung yang mendasarinya (NICE, 2012). Kejang terisolasi yang dipicu oleh penyebab spesifik seperti keracunan tidak dianggap mewakili epilepsi. Orang-orang dengan epilepsi dapat diperlakukan secara berbeda di berbagai area di dunia dan mengalami berbagai tingkat stigma sosial karena kondisinya (Ribeiro & Meneses, 2011).

Diagnosis epilepsi biasanya dibuat berdasarkan pengamatan serangan kejang dan penyebab yang mendasari. Elektroensefalogram (EEG) untuk mencari pola gelombang otak yang abnormal dan neuroimaging (CT scan atau MRI) untuk melihat struktur otak juga biasanya merupakan bagian dari pemeriksaan. Meskipun mencari tahu sindrom epilepsi spessifik sering dicoba, itu tidak selalu mungkin. Dalam kasus –kasus yang sulit kemungkinan bisa menggunakan video dan EEG (NICE, 2012). Peningkatan resiko kejang dapat dibantu oleh aktifitas otak dengan menggunakan Elektroensefalogram (EEG). Kegiatan ini dipergunakan untuk seseorang yang terdapat gejala penyakit epilepsi. Jenis kejang epilepsi dan sindrom dapat dibedakan dengan mendiagnosis penyakit epilepsi dengan menggunakan Elektroensefalgrafi. Kegiatan ini digunkan untuk orang dewasa, sedangkan untuk anak-anak diproses setelah anak tersebut mengalami kejang kedua kalinya. Sehingga kegiatan ini dapat membedakan seseorang yang mempunyai penyakit positif epilepsi dan tidak mempunyai penyakit epilepsi. Dalam situasi tertentu mungkin berguna untuk melakukan EEG saat individu yang terkena sedang tidur atau kurang tidur (NICE, 2012).

Banyak penelitian yang berhubungan dengan deteksi apakah seseorang terkena gangguan epilepsi atau tidak dengan menggunkan sinya EEG. Sinyal EEG tersebut digunakan untuk mendeteksi seseorang mempunyai gangguan epilepsi atau tidak. Penelitian yang mengusulkan teknik hybrid untuk mengklasifikasikan sinyal EEG untuk deteksi kejang epilepsi, yang merupakan kombinasi dari transformasi multi-wavelet dan jaringan saraf tiruan, menghasilakan tingkat akurasi terhadap sinyal kejang normal dan penyakit epilepsy sebesar 90% (Sharanreddy and Kulkarni, 2013). Penelitian dengan menyajikan konsep teknik pengambilan sampel untuk klasifikasi dua kelas dari sinyal EEG dengan menggunakan metode LS-SVM, yaitu orang normal dengan mata terbuka dan pasien epilepsi selama aktivitas kejang epilepsi. Hasil percobaan menunjukkan bahwa akurasi klasifikasi untuk data pelatihan dan pengujian masing-masing adalah 80,31% dan 80,05% (Siuly & Wen, 2009). Interval Type-2 Fuzzy Support Vector Machines untuk menangani masalah klasifikasi yang bertujuan untuk mengklasifikasikan antara tiga fase kejang epilepsi yaitu bebas kejang, pra-kejang dan kejang (Ekong *et al*., 2016). Penelitian yang mengusulkan metode klasifikasi Bayesian untsuk sinyal EEG multivarian (Rincon *et al*., 2018). Penyajian metode baru yang mengekstraksi dan memilih fitur dari sinyal EEG multichannel. Teknik pengambilan sampel acak (SRS) digunakan untuk mengekstraksi fitur dari domain waktu sinyal EEG. Algoritme pemilihan fitur sekuensial (SFS) diterapkan untuk pilih fitur utama dan untuk mengurangi dimensi data. Fitur yang dipilih diteruskan ke untuk mengklasifikasikan LS_SVM untuk mengklasifikasikan sinyal EEG. Hasil percobaan menunjukkan bahwa metode mencapai 99,90, 99,80 dan 100% untuk masing-masing akurasi klasifikasi, sensitivitas dan spesifisitas (Ratham *et al*., 2016). Metode diagnosis otomatis menggunakan JST dirancang untuk mengklasifikasikan Epilepsi dari EEG berdasarkan berbagai tahap tingkat sinyal EEG. Jaringan saraf diimplementasikan untuk mengklasifikasikan Epilepsi berdasarkan tingkat risiko & metode klasifikasi ini memberikan akurasi 96,9% (Priyanka & Dema, 2017). klasifikasi otomatis sinyal EEG untuk mendeteksi serangan epilepsi menggunakan transformasi wavelet dan pengenalan pola statistik. Proses pengambilan keputusan terdiri dari tiga tahap utama: (a) ekstraksi

fitur berdasarkan transformasi wavelet, (b) pengurangan dimensi ruang fitur menggunakan scatter matrices, dan (c) klasifikasi oleh pengklasifikasi quadratic classifiers. Akurasi klasifikasi keseluruhan 99% tercapai. Hasil mengkonfirmasi bahwa Algoritme yang diusulkan memiliki potensi dalam klasifikasi sinyal EEG dan deteksi kejang epilepsi, dan dengan demikian dapat lebih meningkatkan diagnosis epilepsi (Gajic *et al.*, 2014). Klasifikasi sinyal EEG menggunakan jaringan syaraf tiruan (Hindarto and Sumarno, 2016).

Dari latar belakang diatas, banyak peneliti yang melakukan penelitian tentang klasifikasi sinyal EEG diantaranya sinyal Epilepsi dan hasil akurasi dari semua peneliti rata-rata antara 80% samapai 99 %. Sehingga peneliti mencoba untuk meneliti sinyal Epilepsi dengan mengklasifikasikan sinyal epilepsi menggunakan metode KNN dan ekstrasi ciri menggunakan metode Teknik Sampling.

METODE PENELITIAN

1. Bahan

Bahan yanag digunakan dalam penelitian ini berasal dari data publik yang terdiri dari lima set data sinyal epilepsi (data set A, Data set B, data set C, data set D dan data set E) (Epileptic Eeg Data, 2005). Masing-masing set data terdapat 100 sinyal epilepsi dengan satu sensor EEG pemasangannya sesuai dengan standart internasional dan di uji coba dengan mengambil waktu 23.6 detik untuk setiap sinyal. Penelitian ini hanya mengambil dua set data yaitu data set A (orang normal) dan data set E (orang yang mempunyai penyakit epilepsi) (Andrzejak *et al*., 2001)

2. Teknik Sampling

Teknik sampling adalah metode yang dapat digunakan untuk mencari ciri dari sebuah sinyal (NICE, 2012). Pada Gambar 1 proses metode tenik sampling yang akan dilakukan dalam penelitian ini. Satu sinyal epilepsi dibagi menjadi beberapa sub sinyal. Sinyal yang sudah dibagi, kemudian akan dicari nilai rata-rata dan standart deviasinya.

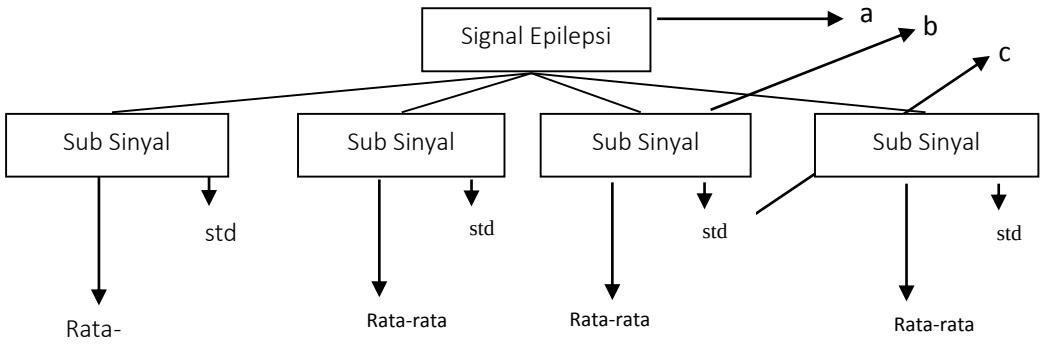

Gambar 1. a. Satu sinyal Epilepsi, b. sub sinyal epilepsi dan c. Ciri sinyal

Pada Gambar 1, terdapat sinyal yang dibagi menjadi empat sub sinyal, yaitu data sinyal epilepsi dan normal. Setiap data tersebut mempunyai 4097 point data. 4097 point data akan dibagi menjadi 4 bagian, sehingga terdapat 1024 point data tiap sinyal. 1024 point data sinyal epilepsi ini akan dicari nilai rata-rata dan nilai standart deviasinya. Sehingga ciri dari tiap sinyal epilepsi mempunyai 2 x 4 sub sinyal, menjadi 8 ciri yang akan dijadikan inputan proses selanjutnya.

3. Metode Klasifikasi *K-Nearest Neighbor*

Algoritme k- Nearest Neighbor (KNN) adalah metode yang sederhana dan mudah untuk diterapkan. Algoritme ini merupakan pembelajaran mesin yang dapat digunakan untuk memecahkan masalah klasifikasi dan regresi. Algoritme pembelajaran mesin yang diawasi (berbeda dengan Algoritme pembelajaran mesin yang tidak diawasi) adalah Algoritme yang mengandalkan data input berlabel untuk mempelajari fungsi yang menghasilkan output yang sesuai ketika diberi data baru tanpa label. Algoritme KNN mengasumsikan bahwa hal serupa ada dalam jarak dekat. Dengan kata lain, hal-hal serupa dekat satu sama lain. 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 (Ko, Majkowski, & Rak, 2010) (Diker *et al*., 2018) (Yazdani, Ebrahimi, & Hoffmann, 2009). KNN menangkap gagasan kesamaan (kadang-kadang disebut jarak, kedekatan, atau kedekatan) dengan beberapa matematika yang mungkin telah kita pelajari di masa kecil kita — menghitung jarak antara titik-titik pada grafik.

Ada cara lain untuk menghitung jarak, dan satu cara mungkin lebih disukai tergantung pada masalah yang kita pecahkan. Namun, jarak garis lurus (juga disebut jarak Euclidean) adalah pilihan yang populer dan akrab.

Algoritme KNN :

1. Ambil data
2. Inisialisasi nilai k
3. Untuk mendapatkan kelas yang diprediksi, beralih dari 1 ke jumlah total poin data pelatihan :
   a. Hitung jarak antara data tes dan setiap baris data pelatihan. Di sini kita akan menggunakan jarak Euclidean sebagai metrik jarak kita karena ini adalah metode yang paling populer. Metrik lain yang dapat digunakan adalah Chebyshev, cosinus, dll.
   b. Urutkan jarak yang dihitung dalam urutan menaik berdasarkan nilai jarak
   c. Dapatkan baris k atas dari array yang diurutkan
   d. Dapatkan kelas paling sering dari baris ini
   e. Kembalikan kelas yang diprediksi

Sebuah kasus diklasifikasikan berdasarkan suara terbanyak dari tetangganya, dengan kasus yang ditugaskan ke kelas yang paling umum di antara tetangga terdekat K diukur dengan fungsi jarak. Jika K = 1, maka kasing sederhana ditugaskan ke kelas tetangga terdekatnya. Euclidean distance direpresentasikan sebagai berikut:

$$j(a,b) = \sqrt{\sum_{k=1}^{k_n}(a_k - b_k)^2} \qquad (1)$$

J (a,b) merupakan jarak antara titik *a* yang merupakan titik yang telah diketahui kelasnya dan *b* berupa titik baru. Jarak antara titik baru dengan titik-titik training dihitung dan diambil *k* buah titik terdekat. Titik baru diprediksi masuk ke kelas dengan klasifikasi terbanyak dari titik-titik tersebut.

Pada penelitian ini metode KNN digunakan karena kesederhanaannya, KNN mudah dimodifikasi untuk masalah klasifikasi yang lebih rumit. Misalnya, KNN sangat cocok untuk kelas multimodal serta aplikasi di mana suatu objek dapat memiliki banyak label kelas. Beberapa peneliti menemukan bahwa KNN

mengungguli pendekatan mesin vektor dukungan (SVM), yang merupakan skema klasifikasi yang jauh lebih canggih (Kuramochi & Karypis, 2001).

HASIL DAN PEMBAHASAN

Proses pertama yang dilakukan oleh peneliti yaitu membagi satu sinyal Epilepsi menjadi 4 bagian sub sinyal. Setelah dibagi menjadi 4 sub sinyal, proses selanjutnya yaitu mencari nilai rata-rata dan standart deviasi dari tiap sub sinyal.

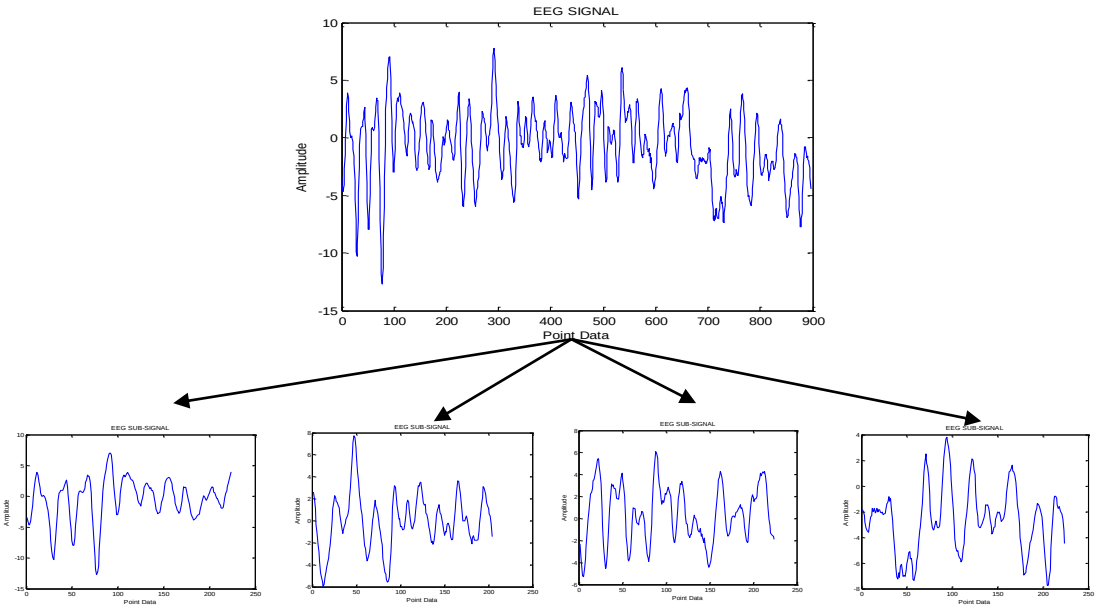

Gambar 2. Satu sinyal dibagi menjadi empat sub sinyal

Pada Gambar 2, menunjukkan hasil pembagian satu sinyal epilepsy dan dari tiap sub sinyal akan dicari nilai rata-rata dan standart deviasi.

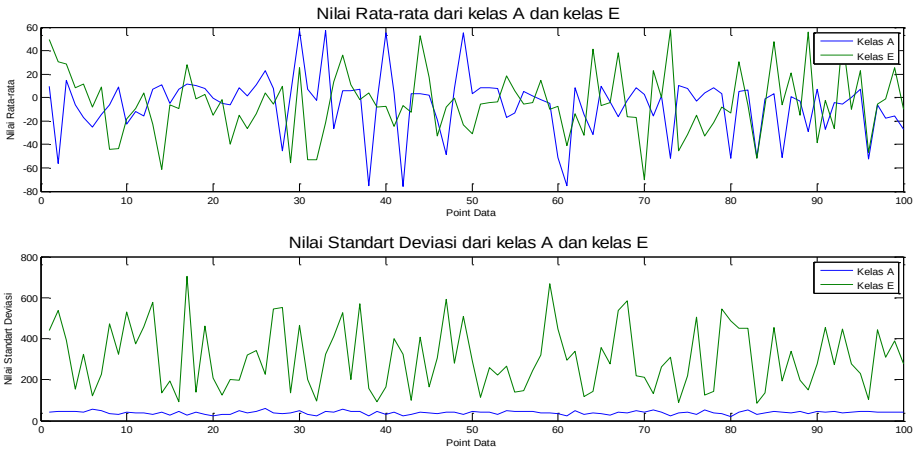

Gambar 3. Hasil setiap sub sinyal yang diambil nilai rata-rata dan dan standart deviasi

Pada Gambar 3, merupakan nilai perbandingan rata-rata dan standart deviasi dari sinyal epilepsy dan sinyal normal, memberikan informasi bahwa nilai rata-rata masing masing data set mempunyai perbedaan yang sedikit, tetapi pada nilai standart deviasi data set A dan data set E mempunyai perbedaan yang sangat tajam. Sehingga dapat diambil kesimpulan bahwa masing-masing data set mempunyai tingkat perbedaan yang hampir mencolok.

Tabel 1. 100 data ciri sinyal Epilepsi dengan mengambil nilai Rata-rata dan standart deviasi

NO	Ciri diambil dari nilai rata-rata dan standart deviasi								KELAS
	R1	R2	R3	R4	S1	S2	S3	S4	
1	9,37	5,73	6,72	5,45	41,57	40,65	40,95	46,86	1
2	-56,13	-51,74	-51,65	-50,25	46,62	46,16	51,19	50,95	1
3	14,83	14,84	10,37	10,78	44,26	49,03	41,01	53,25	1
-	-	-	-	-	-	-		-	-
-	-	-	-	-	-	-	-	-	-
-	-	-	-	-	-	-	-	-	-
							-		
48	8	3,6	2,74	4,43	42,17	44,82	41,38	46,07	1
49	55,55	57,18	56,98	56,78	31,74	30,19	34,38	32,21	1
50	3,23	6,4	0,86	4,79	43,54	50,65	47	57,24	1
51	49,57	39,28	52,38	47,18	440,97	485,85	469,73	515,17	2
52	30,84	41,83	43,86	33,76	538,2	465,67	479,04	534,05	2
53	28,73	32,34	30,15	30,76	394,54	394,17	351,49	354,57	2
-	-	-	-	-	-	-	-	-	-
-	-	-	-	-	-	-	-	-	-
-	-	-	-	-	-	-	-	-	-
98	-0,28	-4,15	-6,26	-5,4	282,24	223,11	251,27	227,63	2
99	-23,01	-13,52	-13,99	-14,97	507,52	537,06	493,31	437,24	2
100	-30,67	-27,1	-33,18	-33,6	292,38	305,09	266,91	204,57	2

Pada Table 1, Kelas 1 diartikan data sinyal Normal, Kelas 2 diartikan data sinyal Epileps merupakan data dari ciri sinyal normal dan sinyal epilepsy, terdapat 100 data sinyal yang diproses dengan mengambil 8 ciri dari masing-masing sinyal. Dari masing-masing sinyal yang terdiri dari 8 ciri akan dicari jarak Euclidean dengan formula seperti diatas.

Tabel 2. Perhitungan jarak Euclidean untuk semua sinyal dengan salah satu data testing

Sinyal Ke	Distance	K=1	K=3	K=5	K=7	K=9	K=11	K=13
1	13,96555047	NAN	NAN	NAN	1	1	1	1
2	114,1627019	NAN	NAN	NAN	NAN	NAN	NAN	NAN
3	27,92259479	NAN	NAN	NAN	NAN	NAN	NAN	NAN
-								
-								
-								
13	19,08679124	NAN	NAN	NAN	NAN	NAN	NAN	1
14	8,655171864	1	1	1	1	1	1	1
15	32,95515438	NAN	NAN	NAN	NAN	NAN	NAN	NAN
16	18,2452624	NAN	NAN	NAN	NAN	NAN	1	1
-								
-								
-								
24	12,83166006	NAN	NAN	1	1	1	1	1
25	27,59794195	NAN	NAN	NAN	NAN	NAN	NAN	NAN
26	40,26528405	NAN	NAN	NAN	NAN	NAN	NAN	NAN
27	13,0421739	NAN	NAN	1	1	1	1	1
28	105,7926992	NAN	NAN	NAN	NAN	NAN	NAN	NAN
29	14,50298935	NAN	NAN	NAN	1	1	1	1

-								
-								
-								
37	15,3237887	NAN	NAN	NAN	NAN	1	1	1
41	18,17807746	NAN	NAN	NAN	NAN	NAN	1	1
43	18,57126813	NAN	NAN	NAN	NAN	NAN	NAN	1
44	15,38243804	NAN	NAN	NAN	NAN	1	1	1
45	11,87105303	NAN	1	1	1	1	1	1
48	12,68962174	NAN	1	1	1	1	1	1
-								
-								
-								
98	415,68839	NAN	NAN	NAN	NAN	NAN	NAN	NAN
99	911,9391896	NAN	NAN	NAN	NAN	NAN	NAN	NAN
100	466,3324265	NAN	NAN	NAN	NAN	NAN	NAN	NAN

Pada Tabel 2, adalah proses pencarian jarak terdekat dengan menggunakan data testing sinyal normal, dari table tersebut data testing dengan K 1 samapai K = 13 masuk ke kelas 1 yaitu data sinyal normal. Data percobaan ini sesuai dengan target yang dicapai yaitu data kelas 1 atau data sinyal normal.

Terdapat 100 data dari masing-masing set data, sehingga pada penelitian ini diambil data 100 untuk proses sampel dan 100 data untuk proses testing. Untuk melatih K-NN menggunakan Set data pelatihan sebanyak 100, sedangkan Untuk memverifikasi keakuratan dan keefektifan K-NN data uji coba menggunakan data 100 data. Pada Proses klasifikasi dengan menggunakan metode KNN, pemilihan nilai K yang bervariasi sangat dibutuhkan untuk proses pengujian (Debo *et al.,* 2014; Labuda *et al.,* 2017; Zhang *et al.*, 2017).

Untuk melakukan analisis klasifikasi maka digunakan alat untuk melakukan analisis, perhitungan tersebut adalah Confusion matrix (Han dan Kamber, 2011). Nilai dari True-Positive dan True-Negative memberikan informasi ketika classifier dalam melakukan klasifikasi data bernilai benar, sedangkan False-Positive dan False-Negative memberikan informasi ketika classifier salah dalam melakukan klasifikasi data. Pada penelitian dari Pengujian tersebut maka akan didapatkan akurasi klasifikasi dengan nilai K yang bervariasi.

Tabel 3. Model dari Confusion Matrix

Aktual	Klasifikasi sebagai	
	+	-
+	True positives (A)	False negatives (B)
-	False positives (C)	True negatives (D)

Perhitungan akurasi dengan Tabel 3, confusion matrix adalah sebagai berikut:

Akurasi = (A+D)/(A+B+C+D)

Dari hasil perhitungan confusion matrix yang dilakukan pada proses klasifikasi pada modul klasifikasi dengan metode kNN, maka dihasilkan ringkasan nilai pada Tabel 4.

Tabel 4. Contoh nilai K=1 pada proses klasifikasi dengan perhitungan confusion matrix

	True Diterima	True Ditolak
Prediksi Diterima	100	0
Prediksi ditolak	0	0

Maka pada Tabel 4, didapatkan nilai akurasi sebesar (100+0)/(100+0+0+0) = 100%. Dengan mengambil nilai K yang bervariasi, maka akan pada penelitian ini didapatkan nilai akurasi. Untuk uji coba dalam penelitian ini nilai K yang di ujikan yaitu K = 1 sampai K=13 dengan hanya mengambil nilai ganjil. Nilai K yang ganjil ini dipilih untuk menghindari kedekatan nilai pada dua titik yang berbeda, mislakan K=1 dengan K=2. Hasil yang didapatkan yaitu semua nilai K yang dipilih didapatkan akurasi sebesar 100%.

KESIMPULAN DAN SARAN

Pada penelitian yang telah didapatkan, maka ada beberapa kesimpulan yang diperoleh yaitu Metode untuk mencari cirri dari sinyal epilepsy menggunakan metode Teknik sampling dengan mengambil nilai rata-rata dan standart deviasi. Untuk proses klasifikasi metode yang digunkan adalah metode KNN. Dari kedua metode tersebut didapatkan tingkat akurasi sebesar 100%. Untuk pengembangan selanjutnya perlu dilakukan untuk beberapa kelas, tidak hanya menggunkan 2 kelas atau dua klaster. Dan metode yang digunakan dalam Uji coba menggunakan metode selain yang sudah dilakukan peneliti.

UCAPAN TERIMA KASIH

Penulis berterima kasih kepada pimpinan universitas muhammadiyah sidoarjo yang memberikan waktu dan dana untuk sehingga penelitian ini dapat terlaksana.

DAFTAR PUSTAKA

Cheng, D., Zhang, S., Deng, Z., Zhu, Y., And Zong, M. (2014). *KNN Algorithm With Data-Driven K Value*. Adma 2014, Lnai 8933, Pp. 499–512, 2014. C Springer International Publishing Switzerland 2014.

Diker, A., Avci, E., Comert, Z., Avci, D., Kacar, E., & Serhatlioglu, I. (2018). *Classification of ECG signal by using machine learning methods*. 2018 26th Signal Processing and Communications Applications Conference (SIU). doi: https://10.1109/siu.2018.8404298.

Eeg Time Series, (Epileptic Eeg Data) (2005, Nov.) [Online], Http://Www.Meb.Uni-Bonn.De/Epileptologie/Science/Physik/Eegdata.Html.

Ekong, U., Lam, H. K., Xiao, B., Ouyang, G., Liu, H., & Chan, K. Y. (2016). *Classification of Epilepsy Seizure Phase using Interval Type-2 Fuzzy Support Vector Machines*. (19), 1–26. doi: https://doi.org/10.1016/j.neucom.2016.03.033

Han, J. dan M. Kamber. 2001. *Data Mining: Concepts and Techniques Tutorial*. Morgan Kaufman Publisher. San Francisco.

Hindarto and Sumarno. (2016). *Feature Extraction Of EEG Signals Using Fast Fourier Transform. CommIT*, 10 (2), 49-52

Gajic, D., Djurovic, Z., Gennaro, S. Di, & Gustafsson, F. (2014). *Classification of EEG signals for detection of epileptic seizures based on wavelets and statistical pattern recognition*. (26).

doi:10.4015/S1016237214500215145002l-1

Ko, M., Majkowski, A., & Rak, R. J. (2010). *A new method of feature extraction from EEG signal for brain- computer interface design*. (9), 35–38.

Sharanreddy, P., Kulkarni, PK (2013). *EEG signal classification for Epilepsy Seizure Detection using Improved Approximate Entropy*. *2*(1). doi: http://dx.doi.org/10.11591/ijphs.v2i1.1836

Natalia Labuda, Julia Seeliger, Tomasz Gedrande, Karol Kozak (2017). *Selecting Adaptive Number Of Nearest Neighbors In K-Nearest Neighbor Classifier Apply Diabetes Data*. Journal Of Mathematics And Statistical Science, 1-13 | Science Signpost Publishing. Published: Volume 2017, Issue 1 / January 25, 2017.

NICE (National Clinical Guideline Centre). *The epilepsies: the diagnosis andmanagement of the epilepsies in adults and children in primary and secondarycare*. http://www.nice.org.uk/nicemedia/live/13635/57784/57784.pdf (accessed Aug 2019).

Pais-Ribeiro J, and Meneses, R. F. (2011). *Management of Epilepsy - Research, Results and Treatmen*. ISBN 978-953-307-680-5 Hard cover, 194 pages Publisher InTech Published online 15, September, 2011 Published in print edition September, 2011.

Priyanka, S., & Dema, D. (2017). Feature Selection and Classification of Epilepsy from EEG Signal. *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)*, (September 2018), 2404–2406. https://doi.org/10.1109/ICECDS.2017.8389880

Ratham, H., Ghayab, A., Li, Y., Abdulla, S., Diykh, M., & Wan, X. (2016). Classification of epileptic EEG signals based on simple random sampling and sequential feature selection. *Brain Informatics*, *3*(2), 85–91. https://doi.org/10.1007/s40708-016-0039-1

Rincon, A. Q., Prendes, J., Pereyra, M. A., Risk, M., Rincon, A. Q., Prendes, J., Risk, M. (2018). *Multivariate Bayesian classification of epilepsy EEG signals To cite this version : HAL Id : hal-01782569*. doi: http://dx.doi.org/10.1109/IVMSPW.2016.7528180

Kuramochi, M. And G. Karypis (2001). *Gene Classification Using Expression Profiles: A Feasibility Study*. In *Bibe '01: Proceedings Of The 2nd Ieee Internationalsymposium On Bioinformatics And Bioengineering*, Page 191, Washington, Dc, 2001. Ieee Computer Society.

Siuly, Li Y., Wen P. (2009) Classification of EEG Signals Using Sampling Techniques and Least Square Support Vector Machines. In: Wen P., Li Y., Polkowski L., Yao Y., Tsumoto S., Wang G. (eds) Rough Sets and Knowledge Technology. RSKT 2009. Lecture Notes in Computer Science, vol 5589. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-02962-2_47.

Shichao Zhang, Xuelong Li, Ming Zong, Xiaofeng Zhu, And Debo Cheng (2017). *Learning K For Knn Classification. Acm Transactions On Intelligent Systems And Technology*, Vol. 8, No. 3, Article 43, Publication Date: January 2017. doi: https://doi.org/10.1145/2990508.

Ralph G Andrzejak, K Lehnertz, F Mormann, C Rieke, P David, And Ce Elger (2001). Indications Of Nonlinear Deterministic And Finite-Dimensional Structures In Time Series Of Brain Electrical Activity: Dependence On Recording Region And Brain State, Phys Rev E Stat Nonlin Soft Matter Phys, Vol. 64, No. 6, Dec 2001, Pp. 061907. doi: http://dx.doi.org/10.1103/physreve.64.061907

Yazdani, A., Ebrahimi, T., & Hoffmann, U. (2009). *Classification Of Eeg Signals Using Dempster Shafer Theory And A K-Nearest Neighbor Classifier*. (1), 327–330. doi: https://doi.org/10.1109/NER.2009.5109299