

Identifikasi Epilepsi Dengan Segmentasi 5 S Pada Klasifikasi Extreme Learning Machine

Siswandari Noertjahjani^{1*}, Yanuarita Tursinawati², Tito Pinandita²,

¹Program Studi Teknik Elektro, Universitas Muhammadiyah Semarang, Indonesia

²Program Studi Kedokteran, Universitas Muhammadiyah Semarang, Indonesia

³Program Studi Teknik Informatika, UMP Purwokerto, Indonesia

Email: ¹siswandari@unimus.ac.id, ²yanuarita@unimus.ac.id, ³titop04@gmail.com

INFORMASI ARTIKEL

Histori artikel:

Naskah masuk, 10 Nopember 2022

Direvisi, 23 Desember 2022

Diiterima, 31 Desember 2022

Kata Kunci:

Mean,
Epilepsi,
Normal

ABSTRAK

Abstract- Epilepsy is a non-infectious disease characterized by seizures due to inappropriate or numerous episodic electrical discharges from nerve cells with various etiologies. EEG is a tool to record epileptic brain waves. EEG recordings that are too long will require high costs and be tedious. Reading a lot of EEG data will also be tiring and confusion can occur. With good digital signal processing, this research uses a method with segmented 5 s signal data in the Temporal region (T3) then after segmentation the mean, variance, standard deviation, kurtosis, and skewness characteristics are calculated. The data used in this research are 75 epileptics and 75 normals. To achieve high accuracy, the classification used Extreme Learning Machine (ELM) on the signal is filtered with least square linear phase FIR convolution. The accuracy results obtained are 99.8% with standard deviation characteristics with 93.3% sensitivity and 96.3% specificity, then variant characteristics with 82.2% accuracy, 80.6% sensitivity and 81.4% specificity.

Abstrak- Epilepsi adalah penyakit tidak menular yang ditandai dengan kejang akibat pelepasan listrik episodik tidak wajar atau banyak dari sel saraf dengan bermacam etiologinya. EEG adalah alat untuk merekam gelombang otak epilepsi. Perekaman EEG yang terlalu lama akan membutuhkan biaya tinggi dan membosankan. Pembacaan data EEG yang banyak juga akan melelahkan dan bisa terjadi kekeliruan. Dengan pengolahan sinyal digital yang baik maka penelitian ini menggunakan metode dengan data yang disegmentasi sinyal 5 s di daerah Temporal (T3) kemudian setelah disegmentasi dihitung ciri *mean*, varian, standar deviasi, kurtosis, dan *skewness*. Data yang digunakan pada penelitian ini adalah 75 epilepsi dan 75 normal. Untuk mencapai akurasi yang tinggi maka klasifikasi yang digunakan *Extreme Learning Machine* (ELM) pada sinyal di filter dengan konvolusi *least square linier phase* FIR. Hasil akurasi yang diperoleh 99,8 % dengan ciri standar deviasi dengan sensivity 93,3 % dan spesitivity 96,3% kemudian ciri varian dengan akurasi 82,2% , sensitivity 80,6% dan spesitivity 81,4%.

Copyright © 2022 LPPM - STMIK IKMI Cirebon
This is an open access article under the CC-BY license

Penulis Korespondensi:

Siswandari Noertjahjani

Program studi Teknik Elektro,

Universitas Muhammadiyah Semarang

Jl. Kedungmundu Raya No. 18

SEMARANG, 50273

Email: siswandari@unimus.ac.id

1. Pendahuluan

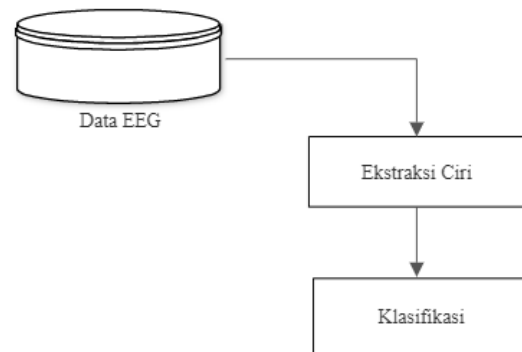
Sinyal electroencephalogram (EEG) digunakan untuk mempelajari aktivitas listrik otak dan terdiri dari beberapa komponen frekuensi [1]. Sinyal-sinyal ini menunjukkan fungsi otak manusia dan kemungkinan adanya gangguan neurologis [2]. Menurut laporan terbaru Organisasi Kesehatan Dunia (WHO), hampir 50.000.000 manusia menderita epilepsi. Epilepsi adalah penyakit saraf yang dapat menyebabkan displasia kortikal, penurunan kognitif dan masalah kesehatan lainnya dan ditandai dengan kejang [3]. Selama epilepsi fokal, kejang tidak dapat dikontrol dengan obat-obatan, jadi penting untuk menemukan zona kejang fokal.

Kasus yang dilaporkan setiap tahun akibat kejang epilepsi seperti berbagai cedera misalnya tenggelam, luka bakar, kecelakaan bahkan kematian. Pemeriksaan visual sinyal EEG oleh dokter yang berpengalaman merupakan metode yang paling penting untuk mendiagnosis epilepsi. Namun, evaluasi sinyal EEG dari rekaman lama oleh dokter spesialis merupakan proses yang memakan waktu, mahal dan membosankan[4]. Metode deteksi epilepsy otomatis perlu dikembangkan karena perekaman EEG jangka panjang sangat memakan waktu dan hasil evaluasi antar pakar berbeda.

Raghu et al.[5] Deteksi epilepsi menggunakan klasifikasi SVM dengan akurasi 96%. Sunaryo et al., [6] mengusulkan klasifikasi Enhanced Gradient Boosting Machines Fusion (Enhanced GBM Fusion) sebelumnya melalui seleksi ciri GA (Genetik Algorithm). Hasil akurasi yang di dapat dari 5 kelas epilepsy adalah 99,7%. Kashif Ahmad Khan et al [7] deteksi serangan menggunakan klasifikasi (Linear Discriminant Analysis (LDA). Rata rata akurasi yang diperoleh adalah 99.6%. Penelitian ini mengembangkan teknik untuk mendeteksi kejang dengan memakai Extreme Learning Machine (ELM). Metode penelitian ini dilakukan dalam beberapa tahapan, yaitu segmentasi/pre-processing data, ekstraksi fitur menggunakan fitur statistik, dan klasifikasi menggunakan ELM. Data input asli merupakan data sinyal EEG orang normal, dan pasien epilepsi. Pada penelitian ini diharapkan dapat memberikan hasil deteksi epilepsi dengan akurasi yang tinggi.

2. Metode

Metode yang dilakukan untuk menganalisa permasalahan diatas dilakukan dalam beberapa tahapan sebagai berikut:



Gambar 1 Blok diagram

Pada Gambar 1 menunjukkan blok diagram penelitian yang diusulkan

2.1 Data EEG

Data EEG yang dipakai ada didaerah temporal lobe yang ditunjukkan pada gambar 3 yaitu elektroda T3 yang ditunjukkan pada gambar 2.

2.2 Ekstraksi ciri [8][9][10]

Ekstraksi adalah teknik penguraian suatu bahan dari campurannya, sedangkan sifat adalah ciri ciri atau sifat khusus dari suatu benda, biasanya didapatkan dari hasil penguraian benda tersebut. Ekstraksi ciri yang dipakai rata-rata, skewness, kurtosis, varian, standardeviasi.

1. Rata-rata

$$\mu = \sum_{i=1}^N \frac{x_i}{N} = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (1)$$

μ = rata-rata,

n = banyaknya data

x_n = data ke n

2. Varian

$$\sigma^2 = \text{varian} \quad \sigma = \sqrt{\sigma^2} \quad (2)$$

3. Standardeviasi =

$$= \sqrt{\frac{\sum_{i=1}^n (x_i - \mu)^2}{n}} \quad (3)$$

σ = standardeviasi

x_i = data ke i

4. Skewness

$$\gamma = \frac{m_3}{m_2^{3/2}} \quad (4)$$

$$m_3 = \frac{(x_i - \mu)^3}{n} \quad (5)$$

$$m_2 = \frac{(x_i - \mu)}{n} \quad (6)$$

5. Kurtosis

Kurtosis merupakan derajat keruncingan dari suatu distribusi. Keruncingan merupakan bentuk distorsi dari kurva normal.

2.3 Klasifikasi

ELM merupakan algoritma pembelajaran yang pada mulanya dikembangkan. SLFN (Single Layer Feedforward Neural Network) sebagai pengganti back propagation. ELM menyediakan proses pembelajaran seribu kali lebih cepat daripada backpropagation, tapi di mana kemampuan lebih bagus untuk menggeneralisasi. Tidak seperti propagasi balik, yang mengulangi serta merubah nilai pada bobot koneksi di antara masing-masing neuron untuk meminimalkan kesalahan, Pada ELM bobot lapisan masukan dan distorsi lapisan tersembunyi bisa diberi dengan nilai random apabila fungsi aktivasi lapisan tersembunyi dapat dibedakan. Hidden node pada ELM dan fungsi aktivasi g dapat ditulis sebagai berikut:

$$\beta^T K = T, \quad (7)$$

dimana

$$K = \begin{bmatrix} g(w_1 x_1 + b_1) & \dots & g(w_1 x_n + b_1) \\ \dots & \dots & \dots \\ g(w_H x_1 + b_H) & \dots & g(w_H x_n + b_H) \end{bmatrix}_{H \times N}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_H^T \end{bmatrix}_{H \times m}, T = [t_1, \dots, t_n]_{m \times n} \quad (8)$$

$w_j = (w_{j1}, w_{j2}, \dots, w_{jd}) =$ weight input pada vector hidden note ke-j dengan node input.

$\beta_j = (\beta_{j1}, \beta_{j2}, \dots, \beta_{jm})^T =$ weight vector hidden note ke-j pada node output.

$B_j =$ bias ke-j

Fungsi aktivasi $g(x)$ dan hidden node berjumlah N

Proses latih ELM:

1. Menetapkan nilai bobot input w_i dan bias $b_i, i = 1, \dots, N$
2. Menghitung nilai matriks K output dari hidden layer.
3. Menghitung bobot dari output β

2.4 Penempatan Elektrode dengan sistim 10-20

Penempatan pada sistim 10-20 diperkenalkan pada kongres internasional EEG ke empat pada tahun 1957.


Prinsip dasar:

1. Letak elektrode pada pengukuran melalui marka standar tulang tengkorak.
2. Penempatannya pada semua daerah kepala.
3. Penentuan posisi menggunakan istilah anatomis otak (frontal, parietal, temporal, oksipital).


4. Masing-masing mempunyai singkatan standard berdasarkan lokasi pada area otak (F, T, P, O).
5. Digunakan nomor ganjil untuk elektrode yang terletak di kiri, dan nomor genap untuk bagian kanan kepala.

Penempatan berdasarkan bidang/baris:

1. Bidang Antero-posterior:
Parasagittal kiri, kanan dan sagittal.
2. Bidang Transverse:
Frontopolar, frontal, sentral/koronal, parietal, oksipital
3. Bidang Horisontal:
Bidang sirkumferensial di atas titik preaurikuler.



Gambar 2 penempatan elektroda 10-20



Gambar 2.3 daerah otak manusia

Secara umum otak terdiri dari bagian kanan dan kiri. Masing-masing di bagi lagi menjadi 4 bagian

1. Lobe Oksipital (*occipital lobe*)

Bagian paling belakang dari otak, bagian ini bertanggung jawab atas imajinasi visual dan merespon rangsangan visual merupakan Lobe Oksipital (*occipital lobe*).

2. Lobe Temporal (*temporal lobe*)

Bagian paling bawah dari otak, bagian ini bertanggung jawab mengorganisir suara, memori, ucapan, dan tanggapan emosional Lobe Temporal

(temporal lobe).

3. Lobe Parietal (*parietal lobe*)

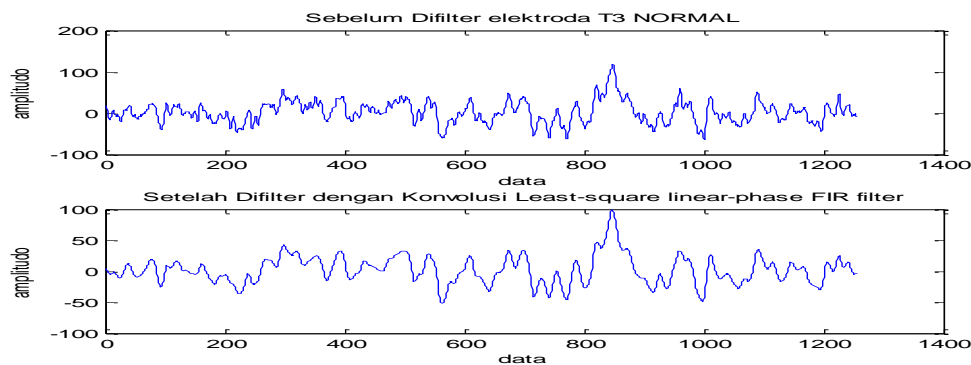
Bagian tengah, yang terletak diantara lobe frontal dan lobe oksipital dari otak, bagian ini bertanggung jawab atas rangsangan seperti sentuhan, nyeri, tekanan, dan suhu tubuh merupakan Lobe Parietal (*parietal lobe*).

4. Frontal Lobe (*frontal lobe*)

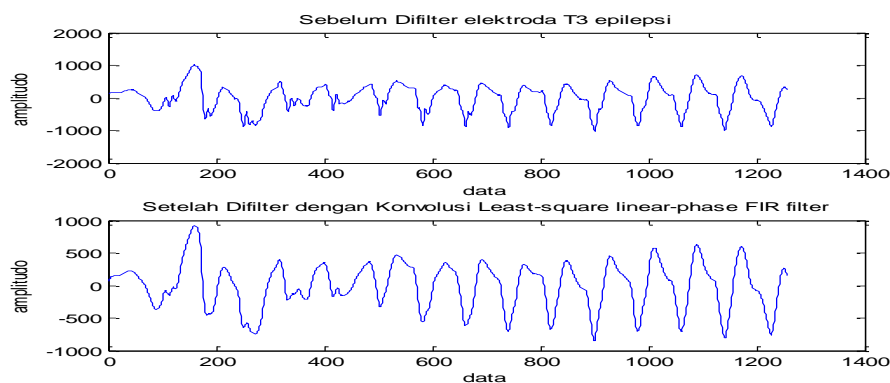
Bagian paling depan dari otak, bagian ini bertanggung jawab dalam memecahkan masalah, memberikan respon spontan, mengambil kenangan, menerapkan penilaian, dan pengendalian impuls. Bagian ini diakui sebagai dasar dari kepribadian dan kontrol dari perilaku manusia pada umumnya. Bagian tersebut biasa disebut Lobe Frontal (*frontal lobe*)

Elektrode ditempatkan pada posisi tertentu pada kulit kepala yang didasarkan kelompok elektrode disekitar *lobe frontal, parietal, temporal* dan *occipital*. Setiap titik penempatan elektrode memiliki satu huruf untuk mengidentifikasi *lobe* dan satu angka setelah huruf yang berfungsi untuk mengidentifikasi lokasi belahan dari tengkorak. Huruf berdasarkan pada huruf pertama bagian kepala seperti F untuk *lobe frontal*, T untuk *lobe temporal*, C untuk *lobe central*, P untuk *lobe parietal* dan O untuk *lobe occipital* sementara angka dimulai dari sisi kiri ke sisi kanan kepala.

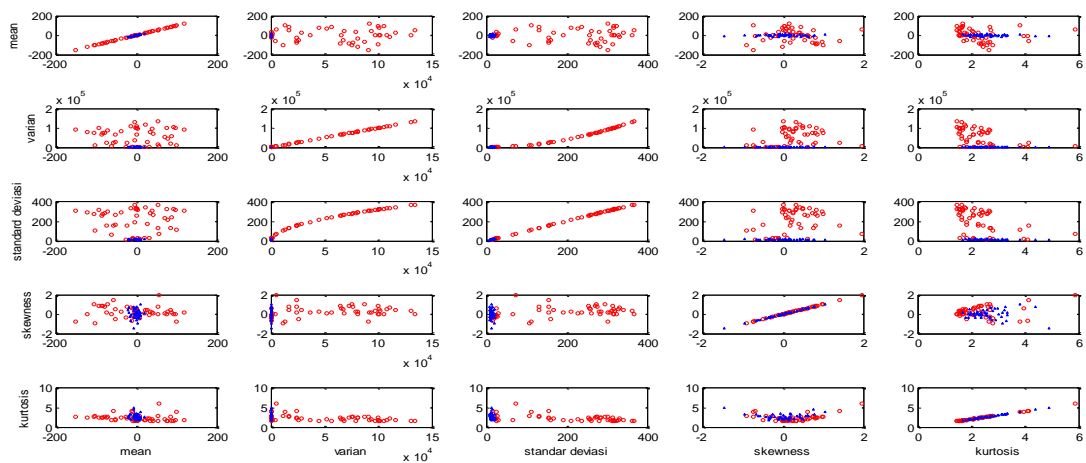
3. Hasil dan Pembahasan



Gambar 4. sinyal T3 normal



Gambar 5. sinyal T3 epilepsi



Gambar 6 plot matriks ekstraksi ciri penyebaran sinyal T3

Tabel 1. Hasil klasifikasi menggunakan ELM

ciri	Akurasi (%)	Sensitivity (%)	spesitiviti (%)
mean	53,6	82,1	90,1
skewness	63,2	81,2	91,2
Kurtosis	76,2	80,3	92,1
Standardevasi	99,8	96,3	92,3
varian	82,2	80,1	81,4

3.1 Data EEG

Data EEG pada sinyal T3 normal ditunjukkan pada gambar 4. Nilai amplitude sebelum difilter maupun sudah dibawah 100. Nilai amplitude sinyal T3 lebih tinggi daripada sesudah di filter. Hal ini akibat filter dengan konvolusi Least square linier untuk mengurangi derau pada sinyal tersebut. Data disegmentasi 5 detik = 1280. Pada gambar 5 menunjukkan sinyal EEG T3 epilepsi dengan nilai amplitude lebih dari 100. Segmentasi sinyal tetap 5 detik dan untuk menghilangkan derau dipakai filter konvolusi Least square linier FIR.

3.2 Ekstraksi ciri

Pada gambar 6 memperlihatkan plot matriks sinyal dari elektroda T3 (temporal). Pada gambar tersebut terlihat jelas bagaimana pentingnya memilih ciri terbaik dari sekumpulan ciri yang sangat banyak untuk digunakan dalam klasifikasi. Ciri standardeviasi tampak jelas terpisah antara epilepsi dan normal (warna merah biru)

3.3 Klasifikasi

Dalam penelitian ini menggunakan metode klasifikasi ELM dengan menggunakan mean, varian,

standardevasi, skewness, kurtosis pada elektroda T3 sebagai input. Parameter klasifikasi ditunjukkan sebagai berikut :

$$Akurasi = \frac{TP + TN}{TP + FP + TN + FN} \times 100\% \quad (1)$$

$$Sensitiviti = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

$$Spesitiviti = \frac{TN}{TN + FP} \times 100\% \quad (3)$$

4. Kesimpulan

Setelah dilakukan segmentasi sinyal, perhitungan ekstraksi ciri, pengujian dan analisis, dapat disimpulkan bahwa klasifikasi menggunakan ELM bisa dipakai untuk identifikasi penyakit epilepsi berdasarkan sinyal EEG. Akurasinya tergolong sangat baik, 99,8% pada ciri standardeviasi. ciri ini mampu memberikan keterpisahan yang cukup signifikan untuk masing-masing klas pada sinyal EEG. Kelas epilepsi dan kelas normal. Sedangkan ciri mean, skewness, kurtosis saling tumpang tindih atas dua kelas (overlapping). Penelitian ini dapat dikembangkan lagi dengan segmentasi sinyal 1,2,3,4 *second* dan klasifikasi metode deep learning.

5. Daftar Pustaka

- [1] A. Zarei and B. M. Asl, "Automatic seizure detection using orthogonal matching pursuit , discrete wavelet transform , and entropy based features of EEG signals," *Comput. Biol. Med.*, vol. 131, no. February, p. 104250, 2021, doi: 10.1016/j.combiomed.2021.104250.
- [2] K. Ahmad, P. P. Shanir, Y. Uzzaman, and O. Farooq, "A hybrid Local Binary Pattern and wavelets based approach for EEG classification for diagnosing epilepsy," vol. 140, 2020, doi: 10.1016/j.eswa.2019.112895.
- [3] E. Tuncer and E. Dog, "Channel based epilepsy seizure type detection from electroencephalography (EEG) signals with machine learning techniques," vol. 42, pp. 575–595, 2022, doi: 10.1016/j.bbe.2022.04.004.
- [4] M. Sharma, S. Patel, and U. R. Acharya, "Automated detection of abnormal EEG signals using localized wavelet filter banks," *Pattern Recognit. Lett.*, vol. 133, pp. 188–194, 2020, doi: 10.1016/j.patrec.2020.03.009.
- [5] S. Raghu, N. Sriraam, Y. Temel, S. Vasudeva, A. Satyaranjandas, and P. L. Kubben, "Performance evaluation of DWT based sigmoid entropy in time and frequency domains for automated detection of epileptic seizures using SVM classifier," *Comput. Biol. Med.*, vol. 110, no. December 2018, pp. 127–143, 2019, doi: 10.1016/j.combiomed.2019.05.016.
- [6] D. Sunaryono, R. Sarno, J. Siswantoro, D. Purwitasari, S. I. Sabilla, and R. Indarto, "Enhanced Gradient Boosting Machines Fusion based on the Pattern of Majority Voting for Automatic Epilepsy Detection," vol. 13, no. 7, pp. 595–604, 2022.
- [7] H. U. Amin, M. Z. Yusoff, and R. F. Ahmad, "Biomedical Signal Processing and Control A novel approach based on wavelet analysis and arithmetic coding for automated detection and diagnosis of epileptic seizure in EEG signals using machine learning techniques," *Biomed. Signal Process. Control*, vol. 56, p. 101707, 2020, doi: 10.1016/j.bspc.2019.101707.
- [8] R. Hussein, M. Elgendi, Z. J. Wang, and R. K. Ward, "PT US CR," *Expert Syst. Appl.*, 2018, doi: 10.1016/j.eswa.2018.03.022.
- [9] M. Y. Member, F. S. Member, and E. Sutanto, "Simple Detection of Epilepsy from EEG Signal using Local Binary Pattern Transition Histogram," *IEEE Access*, vol. PP, p. 1, 2021, doi: 10.1109/ACCESS.2021.3126065.
- [10] Y. Wen *et al.*, "A 65nm / 0 . 448 mW EEG processor with parallel architecture SVM and lifting wavelet transform for high-performance and low-power epilepsy detection," *Comput. Biol. Med.*, vol. 144, no. February, p. 105366, 2022, doi: 10.1016/j.combiomed.2022.105366.