

DETEKSI PENYAKIT EPILEPSI DENGAN LEAST SQUARE ERROR

Siswandari Noertjahjani

Jurusan Teknik Elektro, Universitas Muhammadiyah Semarang

siswandari@unimus.ac.id

Abstrak— Epilepsi didefinisikan sebagai sindrom yang ditandai dengan fungsi otak sesaat dan paroxysm yang dimanifestasikan dalam interupsi atau kehilangan kesadaran, motorik, sensorik, psikologi, otonom gerak, serta episodik. Hambatan utama yang harus dihadapi adalah kurangnya dokter spesialis yang dibutuhkan dan biaya untuk menanganinya pengobatan epilepsi. Penelitian ini ditujukan untuk pengembangan perangkat lunak untuk mendeteksi sindrom epilepsi terhadap sinyal yang terekam dari 7 elektroda dan 3 ciri statistik.

Keberhasilan dari membedakan bentuk sinyal epilepsi dan non epilepsi adalah dilakukan dengan menggunakan ekstraksi ciri kemudian seleksi ciri LSE dan metode klasifikasi dilakukan secara khusus melalui Back propagasi Neural Network (BPNN). Berdasarkan hasil keseluruhan akhir menunjukkan bahwa akurasi dalam deteksi epilepsi dengan seleksi ciri LSE mencapai 96,9%..

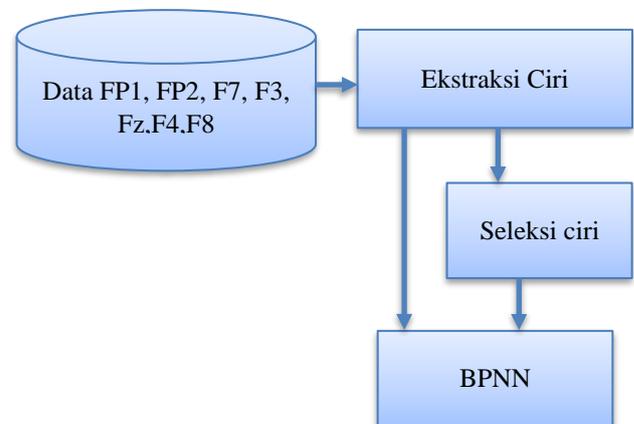
Kata kunci—epilepsi, ekstraksi ciri, seleksi ciri

I. PENDAHULUAN

Epilepsi adalah gejala dan tanda klinis yang terjadi akibat disfungsi otak, akibat pelepasan abnormal, disosiasi paroksismal dari sel saraf berbagai etiologi[1]. Epilepsi adalah gangguan neurologis yang mempengaruhi lebih dari 50 juta orang di seluruh dunia dan dianggap sebagai penyakit paling umum kedua setelah stroke[2][3]. Epilepsi ditandai dengan jumlah listrik yang berlebihan yang dikeluarkan oleh sel-sel otak, sering menyebabkan kejang dan gerakan abnormal. Diagnosis epilepsi dibuat dengan melihat kejang secara langsung, tetapi dokter jarang melihat kejang secara langsung, sehingga diagnosis epilepsi hampir selalu dibuat berdasarkan klinis. Sangat sulit untuk mendapatkan klinik terbaik dan akurat karena gejala yang dijelaskan oleh orang-orang di sekitar pasien seringkali tidak khas, sedangkan pasien sendiri sama sekali tidak menyadari bahwa dia baru saja kejang. Satu-satunya tes yang membantu mendiagnosis epilepsi adalah elektroensefalogram (EEG)[4][5]. Rekaman EEG harus permanen dan dianalisis secara visual oleh spesialis untuk mengidentifikasi epilepsi. Namun, proses ini memakan waktu dan mahal. Masalah lain yang muncul adalah tidak adanya perbedaan yang jelas pada sinyal EEG antara subjek epilepsi dan non-epilepsi.

Beberapa teknik deteksi otomatis telah diuji untuk mempercepat dan meningkatkan akurasi identifikasi bentuk gelombang EEG patologis yang terkait dengan deteksi epilepsi dengan membandingkan kinerja classifier berdasarkan *gradient*

boosting decision tree sinyal EEG dapat menghasilkan akurasi hingga 87,68%.[6]. Deteksi kejang dengan klasifikasi Fuzzy RBFELM mencapai 98% tetapi elektroda yang digunakan tidak disebutkan [7]. Fitur EEG epilepsi menunjukkan jumlah perubahan frekuensi yang lebih besar daripada EEG non-epilepsi. Seleksi fitur adalah proses pemilihan subset dari fitur asli sehingga pengurangan jumlah fitur yang optimal dapat dicapai sesuai dengan kriteria yang ditentukan[8]. Teknik ini telah terbukti efektif dalam mengurangi fitur-fitur yang asing dan berlebihan, meningkatkan efisiensi proses pembelajaran, dan meningkatkan performa pembelajaran seperti akurasi prediksi. Tujuan dari penelitian ini adalah untuk membangun sebuah sistem yang mendeteksi sinyal EEG epilepsi menggunakan domain waktu dan fitur statistik BPNN. Sistem deteksi kejang pada sinyal EEG dapat diimplementasikan menggunakan perangkat lunak yang tertanam di EEG, perangkat nirkabel untuk menentukan kemungkinan epilepsi. Oleh karena itu, sistem klasifikasi diperlukan untuk membuat keputusan yang cepat dan akurat.



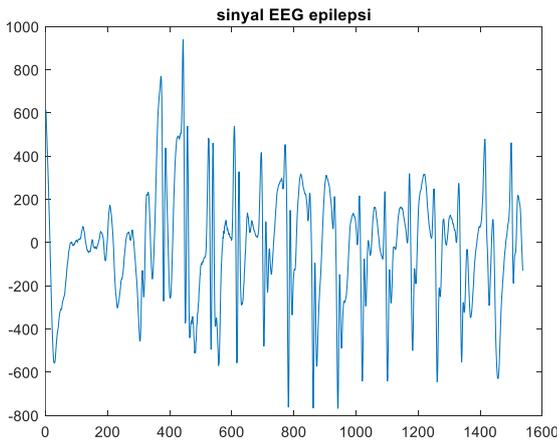
Gambar 1 Diagram blok penelitian

II. DASAR TEORI

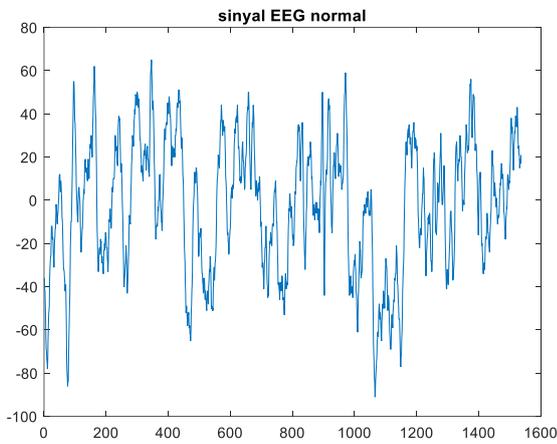
A. Akuisisi Data.

Pada penelitian ini, data EEG yang digunakan di 7 elektroda tu FP1, FP2, F7, F3, Fz, F4, F8 dengan segmentasi 6 detik. Tujuh elektroda ditempatkan di atas kulit pasien menurut Sistem International 10-20, sistem penentuan posisi elektroda dan

frekuensi pengambilan sampel data adalah 256Hz. Gambar 2 menunjukkan sinyal EEG epilepsi dengan 1536 data dan Gambar 3 sinyal EEG normal dengan jumlah data sama.



Gambar 2 sinyal EEG epilepsi



Gambar 3 sinyal EEG Normal

B. Ekstraksi ciri

Langkah pertama dalam ekstraksi fitur ini adalah segmentasi sinyal EEG selama 6 detik untuk menemukan mean, standar deviasi, kurtosis pada setiap elektroda, sehingga membentuk 21 fitur. Data dari ekstraksi fitur secara acak dibagi menjadi pelatihan dan pengujian untuk silang metode validasi, dengan proporsi 40 pelatihan data dan 60 data testing. Pada penelitian ini membandingkan hasil dari ekstraksi fitur langsung diklasifikasikan dengan BPNN dengan ekstraksi fitur melalui seleksi fitur kemudian di klasifikasikan.

C. Seleksi ciri LSE

Setelah proses ekstraksi ciri dilakukan, langkah selanjutnya adalah memilih dan mengklasifikasikan ciri. Pemilihan karakteristik bertujuan untuk mengidentifikasi subset yang optimal atau suboptimal pada karakteristik yang paling

informatif dan prediktif berdasarkan dataset dari karakteristik asli, yaitu untuk

- (1) mengurangi dimensi karakteristik untuk meminimalkan ruang penyimpanan dan meningkatkan kecepatan algoritma;
- (2) menghilangkan data yang berlebihan dan tidak relevan;
- (3) meningkatkan kualitas data;
- (4) meningkatkan model yang dihasilkan;
- (5) menghemat sumber daya pada tahap pengumpulan data atau selama menggunakan;
- (6) meningkatkan kinerja dalam mendapatkan akurasi prediksi;
- (7) pemahaman data, untuk memperoleh pengetahuan tentang proses menghasilkan data atau memvisualisasikan data.

Pemilihan karakteristik yang digunakan dalam penelitian ini adalah LSE. Algoritma memiliki prinsip untuk meminimalkan jumlah kuadrat, diharapkan diperoleh ciri khas sinyal EEG epilepsi dan non epilepsi. Algoritma LSE menentukan kepentingan dari setiap variabel. Pertimbangan fungsi y dibedakan mengilustrasikan sistem masukan n dan keluaran $y = f(x_1, x_2, \dots, x_n), [x_1, x_2, \dots, x_n]^T \in [0,1]^T$ himpunan data pasangan sampel p (pola) dengan fungsi: $[x_{j0,1}, x_{j12}, \dots, x_{jn,n}, y_j], j = 1, \dots, p$.

Perluasan satu titik dari masing-masing dua nilai keluaran, misalnya untuk jdan pola k (y_j dan y_k), dapat didekati dengan deret Taylor, sebagai dijelaskan dengan persamaan (1) dan persamaan (2) sebagai berikut

$$y_j = f(x_1, x_2, \dots, x_n) + \sum_{i=1}^n \frac{\partial f}{\partial x_i} \Big|_{x_i = X_i} (x_{j,i} - X_i) + r_j \quad (2.1)$$

$$y_k = f(x_1, x_2, \dots, x_n) + \sum_{i=1}^n \frac{\partial f}{\partial x_i} \Big|_{x_i = X_i} (x_{k,i} - X_i) + r_k \quad (2.2)$$

Pada persamaan (2.1) dan (2.2) nilai r_j dan r_k berada pada urutan tertinggi, sehingga hal ini dapat diabaikan tanpa banyak kerugian informasi, jika $|x_{j,i} - X_i| < 1$ dan $|x_{k,i} - X_i| < 1$, untuk setiap variable i . Untuk menentukan variasi variabel keluaran, Δy , dengan variasi setiap masukan variabel Δx_i , dilakukan reduksi sebesar persamaan (2.1) dan (2.2), sehingga persamaannya ditulis:

$$y_j - y_k \sum_{i=1}^n b_i (x_{j,i} - x_{k,i}) \quad (2.3)$$

dengan

$$b_i = \frac{\partial f}{\partial x_i} \Big|_{x_i = X_i} \quad (2.4)$$

Fungsi asli kemudian didekati dengan fungsi linear. Pendekatan ini banyak digunakan untuk regresi nonlinear.

Persamaan (2-4) dapat ditulis kembali sebagai fungsi dari kumpulan data dalam jika database berisi pola p , ada $C2$ (jumlah kombinasi dari pasangan data yang diambil dua sekaligus) variasi vektor yang diperoleh dengan mengurangi nilai output dan variabel masukan terkait pola j dari nilai-nilai

output dan variabel input yang terkait dengan pola k. Oleh karena itu, vektor variasi dapat ditulis sebagai:

$$[x_{j,i} - x_{k,i}, \dots, x_{j,n} - x_{k,n}, y_j - y_k]^T \quad (2.5)$$

Karena C2 dapat sangat besar maka hanya vektor variasi q ($\ll C2$) yang dipilih secara acak. Pada kasus ini, persamaan (2.5) menggambarkan variasi variabel output Δ_y kaitannya dengan variasi setiap input ke- i dari variabel Δ_{x_i} atas seluruh set data, sehingga dapat ditulis dalam bentuk matriks sebagai berikut:

$$\Delta_y = \Delta_{xb} \quad (2.6)$$

Dimensi Δ_y , x dan b , masing-masing adalah $q \times 1$, $q \times n$, dan $n \times 1$; b adalah vektor yang elemen-elemennya diketahui dalam parameter persamaan (2.6). Persamaan (2.6) juga dapat dinyatakan sebagai :

$$\Delta_y = b_1[\Delta_{x1}] + b_2[\Delta_2] + b_3[\Delta_3] + \dots + b_n[\Delta_{xn}] \quad (2.7)$$

dengan dimensi Δ_y , Δ_{xb} masing-masing adalah $q \times 1$, $q \times n$, dan $n \times 1$. Persamaan (2.6) dan (2.7) dapat diverifikasi bahwa setiap elemen dari vektor b (masing-masing b_i , merupakan rasio antara varians dari variabel output y dan varians dan masing-masing variabel input x_i atas seluruh data. Oleh karena itu, nilai b ; menunjukkan pentingnya input yang sesuai. Namun, jika $q > n$ dalam persamaan (2.6), maka untuk memperoleh b menjadi sangat rumit dengan tanpa solusi yang tepat. Sebaliknya, algoritma ini dapat digunakan untuk menentukan estimasi kuadrat terkecil dari nilai tersebut, yaitu dengan meminimumkan kesalahan kuadrat $|\Delta_{xb} - \Delta_y|^2$ dan dapat dievaluasi dengan formula pseudo-invers. Hasilnya, nilai b bisa positif atau negatif, maka $\text{impo}(x_i)$ untuk mewakili tingkat pentingnya x_i seperti pada persamaan berikut :

$$\text{Impo}(x_i) = \frac{|b_i|}{\sum_{j=1}^n |b_j|} \quad (2.8)$$

Yang berarti

$$\sum_{i=1}^n \text{Impo}(x_i) = 1 \quad (2.9)$$

D. BPPN

Klasifikasi ciri pada sistem ini adalah dengan menggunakan BPNN. Masukan jaringan BPNN adalah vektor ciri dimensi waktu dan dimensi waktu frekuensi terpilih dari masing-masing jenis kelas dari sinyal EEG. Keluaran jaringan yang diharapkan adalah 2 kelas yang terdiri dari kelas 1 merupakan kelompok epilepsi, kelas 2 untuk kelompok normal. Berdasarkan hal hal di atas maka dibangun jaringan dengan jumlah input neuron yang berbeda-beda tergantung ukuran vektor ciri. Adapun jumlah neuron keluaran sesuai dengan jumlah kelas yang diharapkan yaitu 2 neuron. Ada dua proses utama yang berlangsung pada jaringan BPNN yang dibangun, yaitu proses pelatihan jaringan dan proses klasifikasi sinyal EEG.

III. HASIL DAN PEMBAHASAN

Pada penelitian ini, implementasi dilakukan dengan menggunakan MATLAB 2018a dengan hasilnya

A. Ekstraksi fitur

Pada proses ekstraksi ciri dilakukan pada sinyal EEG epilepsi dan normal. Hasil dari ekstraksi fitur dapat terlihat pada tabel 1 dan tabel 2 dimana nilai rata-rata dan kurtosis antara elektroda FP1, FP2, F7, F3, Fz, F4, F8 memiliki interval yang tidak beraturan. Ciri standar deviasi pada tabel 1 memiliki interval yang besar dibandingkan dengan ciri standardeviasi pada tabel 2.

B. Seleksi ciri LSE

Pemilihan fitur menggunakan fitur algoritma LSE adalah diurutkan ke dalam satu kumpulan fitur terdiri dari rata-rata, standar deviasi, kurtosis, energi.

Fitur Y masukan dari masing-masing vektor fitur Y1 sampai 21 berturut-turut adalah fitur standar deviasi FP1, standar deviasi FP2, standar deviasi F7, standar deviasi F3, standar deviasi Fz, standar deviasi F4, standar deviasi F8, kurtosis FP1, kurtosis FP2, kurtosis F7, kurtosis F3, kurtosis Fz, kurtosis F4, kurtosis F8, mean FP2, mean FP1, mean F3, mean F8, mean F4, mean Fz, mean F7. Pada table 3 menunjukkan 14 fitur hasil seleksi ciri .

C. Confusion matrix

Cara yang dipakai untuk evaluasi sistem dan efisiensi adalah dengan Confusion matrix.

Aktual	Prediksi	
	Positif	Negatif
Positif	True Positif (TP)	False Negatif (FN)
Negatif	False Positif (FP)	True Negatif (TN)

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

$$\text{Sensitivitas} (\%) = \frac{TP}{TP + FN} \times 100\%$$

$$\text{Spesifisitas} (\%) = \frac{TN}{FP + TN} \times 100\%$$

Setelah melalui proses segmentasi 6 detik kemudian ekstraksi ciri mean standar deviasi kurtosis dan seleksi ciri LSE akurasi tertinggi mencapai 96,9 % dengan sensitivitas 91% dan spesifisitas 86 % pada elektroda FP1 dengan ciri standardeviasi. Sedangkan tanpa seleksi ciri akurasi tertinggi pada ciri standar deviasi elektroda FP1 mencapai 84 % dengan sensitivitas 82% dan spesifisitas 83%.

Tabel 1
Ekstraksi ciri EEG epilepsi

No	electrode	mean	Standard deviation	kurtosis
1	FP1	-150-223	8,61-366	-1,06-1,27
2	Fp2	-324-272	14,1-423	1,57-5,41
3	F7	146-122	17,0-603	1,53-6,32
4	F3	-192-251	19,7-664	1,30-6,43
5	Fz	-124-263	16,2-489	1,42-6,11
6	F4	-131-373	21,6-680	1,17-6,10
7	F8	-221-242	21,4-496	1,4-5,1

Tabel 2
Ekstraksi ciri EEG normal

No	electrode	mean	Standard deviation	kurtosis
1	FP1	-151-103	3,1-135	1,5-5,1
3	FP2	-131-101	6,1-93	1,6-5,3
3	F7	-331-151	10-116	1,5-6,3
5	F3	-331-115	10,35-119	1,5-5,3
5	Fz	-191-151	10,3-156	1,6-5,3
6	F5	-331-163	10,3-169	1,5-6,1
7	F8	-193-160	1,1-153	1,5-5

Tabel 3
Hasil seleksi ciri

No	Electrode (Y1)
1	Standardevisi FP1
3	Standardevisi FP2
3	Standardevisi F3
5	Standardevisi F7
5	Standardevisi Fz
6	Standardevisi F4
7	Standardevisi F8
8	Kurtosis FP1
9	Kurtosis FP2
10	Kurtosis F7
11	Kurtosis F3
12	Kurtosis Fz
13	Kurtosis F4
14	Kurtosis F8

IV. KESIMPULAN

Hasil ekstraksi fitur berdasarkan karakteristik dari rata-rata statistik, standar deviasi, kurtosis.

Sinyal EEG memiliki nilai normal elektroda yang sangat kecil jangkauan atau pendek sedangkan elektroda sinyal epilepsi memiliki sangat jarak jauh sehingga dapat dikatakan bahwa penyebaran data untuk orang normal berkumpul sementara epilepsi menyebar. Pemilihan fitur Ise menggunakan algoritma domain waktu adalah mampu mendeteksi epilepsi diwakili oleh karakteristik vektor standar deviasi dari masing-masing elektroda FP1, FP2, F3.

Klasifikasi BPNN mampu mengenali dan mengklasifikasikan kelas epilepsi dan non-epilepsi dengan tingkat akurasi yang relatif lebih tinggi sebesar 96,9% dengan metode klasifikasi tanpa seleksi ciri 84%.

Daftar Pustaka

- [1] R. P. Mcinnis, M. Abubakar, J. Jing, J. J. Halford, F. J. Mateen, and M. B. Westover, "Epilepsy & Behavior Epilepsy diagnosis using a clinical decision tool and artificially intelligent electroencephalography," *Epilepsy Behav.*, vol. 141, p. 109135, 2023, doi: 10.1016/j.yebeh.2023.109135.
- [2] Kumar, Y., Dewal, M.L., and Anand, R.S., 2014 Epileptic seizure detection using dwt based fuzzy approximate entropi and support vector machine, *Journal of Neurocomputing* 133, 271- 279.
- [3] 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.
- [4] H. He, X. Liu, and Y. Hao, "A progressive deep wavelet cascade classification model for epilepsy detection," *Artif. Intell. Med.*, vol. 118, no. April, p. 102117, 2021, doi: 10.1016/j.artmed.2021.102117.
- [5] Z. Telatar, "Biomedical Signal Processing and Control Automated temporal lobe epilepsy and psychogenic nonepileptic seizure patient discrimination from multichannel EEG recordings using DWT based analysis," vol. 77, no. May, 2022, doi: 10.1016/j.bspc.2022.103755.
- [6] Hezam Albaqami, Ghulam Mubashar Hassan, Automatic detection of abnormal EEG signals using wavelet feature extraction and gradient boosting decision tree, *Biomedical Signal Processing and Control* 70 (2021) 102957
- [7] A Harishvijey, J Benadic Raja, Automated technique for EEG signal processing to detect seizure with optimized Variable Gaussian Filter and Fuzzy RBFELM classifier, *Biomedical Signal Processing and Control* 74(2022) 103450
- [8] Mollae, M. and Moattar, M.H., 2016, A novel feature extraction approach based on ensemble feature selection and modified discriminant independent component analysis for microarray data classification, *Journal of Biocybe Netics And Bio Medical Engineering*, 36:521 – 529.

