

Representasi Distribusi Energi EEG Multi-Channel untuk Deteksi Aktivitas Epilepsi Menggunakan SVM

Siswandari Noertjahjani¹, Ratih Sari Wardani², Aris Kiswanto³

^{1,3} Jurusan Rekayasa Elektro, Universitas Muhammadiyah Semarang

² Jurusan Magister Kesehatan Masyarakat, Universitas Muhammadiyah Semarang

Korespondensi: siswandari@unimus.ac.id

Abstrak

Deteksi epilepsi berbasis electroencephalogram (EEG) menghadapi tantangan berupa ketidakseimbangan kelas, data leakage, dan variasi sinyal antarpasien. Penelitian ini mengusulkan representasi distribusi energi EEG multikanal menggunakan Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF). Dataset CHB-MIT dipreproses dan disegmentasi menjadi window berdurasi 2 detik dengan overlap 25%. Setiap window direpresentasikan oleh 23 fitur energi domain waktu dan 23 fitur Power Spectral Density (PSD) metode Welch, sedangkan energy map berukuran 23×16 digunakan sebagai visualisasi distribusi energi kanal-waktu dan bukan sebagai masukan model. Evaluasi dilakukan menggunakan independent file-wise testing, grouped file-wise 5-fold cross-validation, dan patient-wise Leave-One-Subject-Out (LOSO). Untuk mencegah data leakage, pembagian data dilakukan pada tingkat file atau pasien sebelum segmentasi, sedangkan undersampling dan standardisasi hanya diterapkan pada data pelatihan. Hasil file-wise testing menunjukkan akurasi 93,247%, sensitivitas 98,387%, F1-score 42,958%, dan ROC-AUC 0,9880. Pada evaluasi LOSO, akurasi, sensitivitas, dan F1-score menurun menjadi 78,071%, 51,909%, dan 20,550%, yang menunjukkan adanya inter-subject variability. Uji Mann-Whitney menunjukkan perbedaan distribusi energi yang signifikan antara kelas seizure dan non-seizure ($p = 2,1804 \times 10^{-140}$). Metode ini efektif untuk deteksi antarfile pada pasien yang sama, namun masih memerlukan validasi lintas pasien dan dataset eksternal untuk meningkatkan kemampuan generalisasi.

Kata kunci: CHB-MIT, deteksi epilepsi, distribusi energi EEG, patient-wise LOSO, SVM.

I. PENDAHULUAN

Epilepsi merupakan gangguan neurologis yang ditandai oleh aktivitas listrik otak abnormal sehingga menyebabkan seizure berulang. Electroencephalogram (EEG) menjadi modalitas utama dalam diagnosis epilepsi karena mampu merekam aktivitas listrik otak dengan resolusi temporal tinggi. Namun, interpretasi rekaman EEG multikanal secara manual memerlukan waktu, bergantung pada pengalaman klinisi, dan berpotensi menimbulkan variasi hasil. Oleh karena itu, berbagai metode pemrosesan sinyal dan machine learning terus dikembangkan untuk mendukung deteksi epilepsi secara otomatis [2], [5]–[7], [17]. Selama seizure, sinyal EEG mengalami perubahan amplitudo, distribusi energi, dan karakteristik spektral. Perubahan tersebut dapat direpresentasikan menggunakan energi domain waktu dan Power Spectral Density (PSD). Energi menggambarkan intensitas aktivitas listrik pada setiap kanal, sedangkan PSD metode Welch memberikan informasi distribusi daya pada domain frekuensi dengan estimasi spektrum yang stabil. Kombinasi kedua fitur tersebut menghasilkan representasi temporal dan spektral yang saling melengkapi sehingga sesuai digunakan sebagai masukan Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF) [3], [4], [8].

CHB-MIT Scalp EEG Database merupakan dataset publik yang banyak digunakan dalam penelitian deteksi epilepsi berbasis EEG. Namun, perbandingan performa antarpelatihan tidak dapat hanya didasarkan pada akurasi karena dipengaruhi oleh strategi preprocessing, segmentasi, penanganan ketidakseimbangan data, dan protokol validasi yang berbeda [1], [5], [6]. Pada data EEG yang sangat tidak seimbang, sensitivitas, spesifisitas, F1-score, false negative rate (FNR), dan ROC-AUC memberikan gambaran performa yang lebih representatif dibandingkan akurasi.

Selain ketidakseimbangan kelas, penelitian deteksi epilepsi juga menghadapi risiko data leakage, yaitu ketika window dari file atau pasien yang sama muncul pada data pelatihan dan pengujian sehingga menghasilkan estimasi performa yang terlalu optimistik. Risiko tersebut semakin besar apabila segmentasi dilakukan menggunakan sliding window yang saling tumpang tindih. Oleh karena itu, pembagian data harus dilakukan pada tingkat file atau pasien sebelum segmentasi, sedangkan evaluasi patient-wise Leave-One-Subject-Out (LOSO) diperlukan untuk menilai kemampuan generalisasi model terhadap pasien yang belum pernah digunakan selama pelatihan [10], [13].

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan representasi distribusi energi EEG multikanal menggunakan 23 fitur energi domain waktu dan 23 fitur PSD Welch sebagai masukan SVM-RBF, serta energy map berukuran 23×16 sebagai visualisasi interpretatif yang terpisah dari proses klasifikasi. Evaluasi dilakukan menggunakan independent file-wise testing, grouped file-wise 5-fold cross-validation, dan patient-wise LOSO dengan pemisahan data berdasarkan identitas file atau pasien sebelum segmentasi. Pendekatan ini bertujuan mengurangi risiko data leakage, meningkatkan interpretabilitas distribusi energi EEG, dan memberikan evaluasi yang lebih andal terhadap kemampuan generalisasi model.

II. TINJAUAN PUSTAKA

2.1 EEG dan Dataset CHB-MIT

Electroencephalogram (EEG) merupakan metode noninvasif untuk merekam aktivitas listrik otak melalui elektroda yang dipasang sesuai International 10–20 System. EEG memiliki resolusi temporal yang tinggi sehingga mampu menggambarkan perubahan aktivitas otak selama kondisi normal maupun seizure. Penelitian ini menggunakan CHB-MIT Scalp EEG Database, yaitu dataset publik yang banyak digunakan dalam pengembangan metode deteksi epilepsi karena menyediakan rekaman EEG multikanal beserta anotasi seizure yang telah diverifikasi oleh ahli neurologi [1], [2].

2.2 Representasi Energi dan Power Spectral Density

Aktivitas seizure menyebabkan perubahan amplitudo, distribusi energi, dan spektrum frekuensi sinyal EEG. Oleh karena itu, penelitian ini menggunakan energi domain waktu dan Power Spectral Density (PSD) sebagai representasi utama sinyal. Energi menggambarkan intensitas aktivitas listrik pada setiap kanal, sedangkan PSD metode Welch memberikan estimasi distribusi daya pada domain frekuensi yang lebih stabil melalui proses windowing dan averaging.

Kombinasi kedua fitur tersebut menghasilkan representasi temporal dan spektral yang saling melengkapi sehingga mampu meningkatkan kemampuan diskriminasi antara kelas seizure dan non-seizure [3], [4], [16].

2.3 Support Vector Machine dan Interpretabilitas

Support Vector Machine (SVM) merupakan algoritma klasifikasi yang efektif untuk data berdimensi tinggi dengan jumlah sampel terbatas. Penggunaan kernel Radial Basis Function (RBF) memungkinkan pemisahan kelas yang bersifat nonlinier sehingga banyak diterapkan pada analisis sinyal EEG [4], [9]. Selain performa klasifikasi, penelitian ini juga menekankan aspek interpretabilitas melalui energy map berukuran 23×16 yang menampilkan distribusi energi berdasarkan kanal dan waktu. Energy map digunakan sebagai visualisasi interpretatif untuk membantu memahami perubahan energi selama seizure dan tidak digunakan sebagai masukan model SVM [12]–[15].

2.4 Validasi Model dan Research Gap

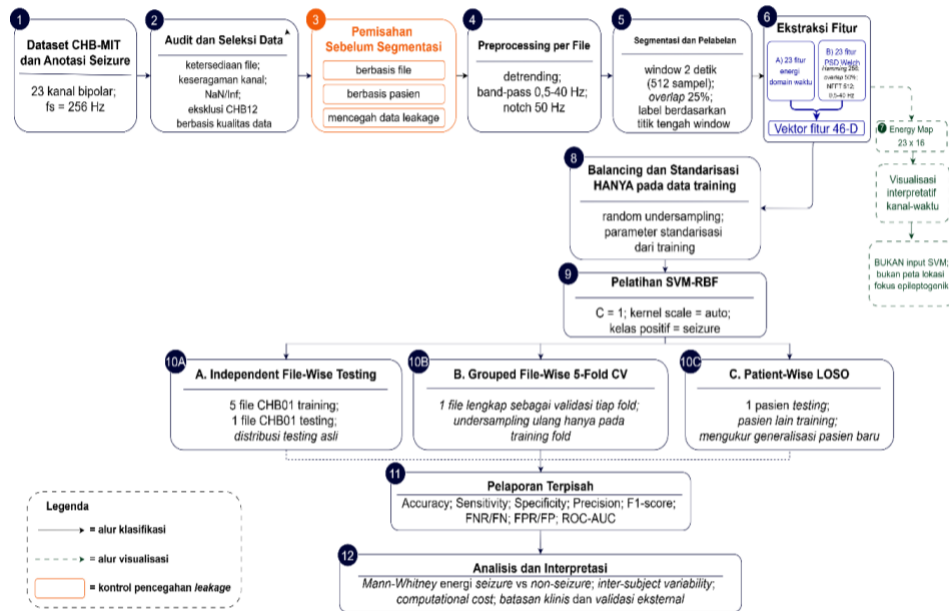
Keandalan sistem deteksi epilepsi tidak hanya ditentukan oleh akurasi, tetapi juga oleh strategi validasi. Pembagian data pada tingkat segmen dapat menimbulkan data leakage apabila window dari file atau pasien yang sama muncul pada data pelatihan dan pengujian. Oleh karena itu, penelitian terkini lebih menekankan file-wise validation dan patient-wise Leave-One-Subject-Out (LOSO) untuk memperoleh estimasi kemampuan generalisasi yang lebih realistis [5], [10], [13].

Meskipun berbagai penelitian telah melaporkan performa deteksi epilepsi yang tinggi, sebagian besar masih berfokus pada peningkatan akurasi, sementara pembahasan mengenai pencegahan data leakage, validasi lintas pasien, dan interpretabilitas distribusi energi EEG masih terbatas. Pendekatan ini diharapkan memberikan evaluasi yang lebih andal sekaligus meningkatkan interpretasi distribusi energi EEG pada deteksi aktivitas epilepsi.

III. METODE PENELITIAN

3.1 Desain dan Pipeline Penelitian

Penelitian ini merupakan studi eksperimental untuk mendeteksi aktivitas epilepsi pada sinyal electroencephalogram (EEG) menggunakan Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF). Tahapan penelitian meliputi audit dan seleksi data, pemisahan data sebelum segmentasi, preprocessing, segmentasi dan pelabelan, ekstraksi fitur, pembentukan *energy map*, pelatihan model, validasi, dan evaluasi performa. Pipeline penelitian ditunjukkan pada Gambar 1.



Gambar 1. Pipeline penelitian representasi distribusi energi EEG multikanal untuk deteksi aktivitas epilepsi menggunakan SVM

3.2 Dataset EEG

Penelitian menggunakan CHB-MIT Scalp EEG Database dengan frekuensi sampling 256 Hz. Sebanyak 11 pasien dipilih berdasarkan ketersediaan anotasi seizure, kualitas sinyal, dan keseragaman konfigurasi 23 kanal bipolar. Pasien CHB08 tidak digunakan karena data tidak tersedia, sedangkan CHB12 dikeluarkan karena beberapa file memiliki kanal yang seluruh nilainya tidak valid.

Untuk mencegah data leakage, pembagian data dilakukan pada tingkat file atau pasien sebelum segmentasi sehingga seluruh window dari file atau pasien yang sama hanya berada pada satu kelompok data. Evaluasi file-wise menggunakan enam file CHB01, sedangkan evaluasi patient-wise LOSO menggunakan seluruh data dari 11 pasien. Pembagian data ditunjukkan pada Tabel 1 dan Tabel 2.

Tabel 1. Pembagian file dan anotasi seizure pada evaluasi file-wise CHB01

File	Partisi	Awal (s)	Akhir (s)	Durasi (s)
chb01_03	Training	2996	3036	40
chb01_04	Training	1467	1494	27
chb01_15	Training	1732	1772	40
chb01_16	Training	1015	1066	51
chb01_18	Training	1720	1810	90
chb01_21	Testing	327	420	93

Tabel 2. Daftar file dan anotasi seizure pada evaluasi patient-wise LOSO

Pasien	File pertama	Awal (s)	Akhir (s)	File kedua	Awal (s)	Akhir (s)
CHB01	chb01_03_data.mat	2996	3036	chb01_04_data.mat	1467	1494
CHB02	chb02_16+_data.mat	2972	3053	chb02_19_data.mat	3369	3378
CHB03	chb03_01_data.mat	362	414	chb03_02_data.mat	731	796
CHB04	chb04_05_data.mat	7804	7853	chb04_08_data.mat	6446	6557
CHB05	chb05_06_data.mat	417	532	chb05_13_data.mat	1086	1196
CHB06	chb06_09_data.mat	12500	12516	chb06_10_data.mat	10833	10845
CHB07	chb07_12_data.mat	4920	5006	chb07_13_data.mat	3285	3381
CHB09	chb09_06_data.mat	12231	12295	chb09_19_data.mat	5299	5361
CHB10	chb10_27_data.mat	2382	2447	chb10_30_data.mat	3021	3079
CHB11	chb11_82_data.mat	298	320	chb11_92_data.mat	2695	2727
CHB13	chb13_19_fixed_data.mat	2077	2121	chb13_21_fixed_data.mat	934	1004

3.3 Preprocessing EEG

Tahapan *preprocessing* meliputi pemeriksaan orientasi matriks EEG, pemilihan 23 kanal, pemeriksaan nilai NaN/Inf, *detrending*, band-pass filter 0,5–40 Hz, notch filter 50 Hz, dan normalisasi amplitudo. Proses *filtering* dilakukan menggunakan metode forward-backward untuk menghindari pergeseran fase.

3.4 Segmentasi dan Pelabelan

Sinyal EEG disegmentasi menggunakan metode sliding window sepanjang 2 detik (512 sampel) dengan overlap 25%, sehingga menghasilkan step size sebesar 384 sampel. Jumlah window dihitung berdasarkan panjang rekaman, panjang window, dan step size. Pelabelan dilakukan menggunakan titik tengah window. Sebuah window diberi label *seizure* apabila titik tengahnya berada pada interval anotasi *seizure*, sedangkan window lainnya diberi label *non-seizure*. Pendekatan ini menghasilkan aturan pelabelan yang konsisten pada batas awal maupun akhir *seizure*.

3.5 Ekstraksi Fitur

3.5.1 Energi Domain Waktu

Energi dihitung untuk setiap kanal dan window:

$$E_{c,w} = \sum_{n=1}^N |x_{c,w}(n)|^2$$

$E_{c,w}$: energi kanal ke- c pada window ke- w .

$x_{c,w}(n)$: amplitudo sampel ke- n

N : jumlah sampel dalam satu window

3.5.2. Ekstraksi PSD Welch

PSD dihitung menggunakan metode Welch untuk memperoleh distribusi daya pada domain frekuensi. Parameter Welch PSD yang digunakan dalam penelitian ini meliputi window Hamming dengan panjang 256 sampel (1 detik), overlap 128 sampel (50%), NFFT 512, serta analisis pada rentang frekuensi 0,5–40 Hz. Konfigurasi ini dipilih untuk menghasilkan estimasi spektrum daya yang stabil. Setiap segmen dua detik dianalisis menggunakan window Hamming sepanjang 256 sampel dengan overlap 128 sampel dan NFFT 512. Nilai PSD pada rentang 0,5–40 Hz diintegrasikan untuk menghasilkan satu fitur daya pada setiap kanal.

PSD kanal dihitung menggunakan:

$$P_{c,w} = \int_{0.5}^{40} PSD_{c,w}(f) df$$

Hasil integral PSD menghasilkan satu fitur daya untuk setiap kanal. Dengan 23 kanal, diperoleh 23 fitur PSD pada setiap window, sehingga setiap segmen menghasilkan 46 fitur.

3.6 Struktur Fitur SVM

Setiap window direpresentasikan oleh:

$$X_w = [E_{1,w}, \dots, E_{23,w}, \dots, P_{1,w}, \dots, P_{23,w}]$$

dengan 23 fitur energi domain waktu dan 23 fitur Power Spectral Density (PSD) Welch, sehingga setiap window menghasilkan 46 fitur sebagai masukan model Support Vector Machine (SVM). Matriks fitur dinyatakan sebagai

$$X \in \mathbb{R}^{W \times 46}$$

dengan W sebagai jumlah window EEG.

3.7 Pembentukan Energy Map

Setiap window dibagi menjadi 16 bin waktu. Energi dihitung pada setiap kanal dan bin:

$$Mw(c, b) = n = nbnb + 1 - 1 \times c, w(n)2$$

Energy map dinyatakan sebagai:

$$M_w \in \mathbb{R}^{23 \times 16}$$

c : kanal EEG.

b : bin waktu.

$M_w(c, b)$: energi kanal pada bin tertentu.

Baris energy map menunjukkan kanal bipolar, kolom menunjukkan bin waktu, dan intensitas warna menyatakan besar energi. Representasi kanal–waktu digunakan untuk visualisasi interpretatif [12]–[14], [19] dan bukan sebagai input SVM.

3.8 Protokol Evaluasi

3.8.1 Independent File-Wise Testing

lima file CHB01 sebagai data pelatihan dan satu file berbeda sebagai data pengujian. Ketidakteraturan identitas file training dan testing diverifikasi menggunakan:

$$\mathcal{F}_{\text{train}} \cap \mathcal{F}_{\text{test}} = \emptyset$$

Kondisi tersebut mencegah window dari file testing masuk ke training.

3.8.2 Grouped 5-Fold Cross-Validation

Satu file digunakan sebagai data validasi pada setiap *fold*, sedangkan empat file lainnya sebagai data pelatihan. Proses *undersampling* dan standarisasi dilakukan kembali pada setiap *fold*.

Setiap file digunakan sebagai validasi satu kali. Standard error dihitung dari akurasi antar-fold:

$$SE = \frac{s}{\sqrt{k}}$$

dengan s sebagai standar deviasi akurasi fold dan $k = 5$.

3.8.3 Patient-Wise Leave-One-Subject-Out

Seluruh data dari satu pasien digunakan sebagai data pengujian, sedangkan data dari pasien lain digunakan sebagai pelatihan. Pendekatan ini digunakan untuk mengevaluasi kemampuan generalisasi model terhadap pasien yang belum pernah digunakan selama proses pelatihan.

Kondisi pemisahan pasien dinyatakan sebagai:

$$\mathcal{P}_{\text{train}} \cap \mathcal{P}_{\text{test}} = \emptyset$$

Patient-wise LOSO lebih kuat daripada segment-wise split karena model diuji pada pasien yang tidak pernah digunakan selama training.

3.9 Penanganan Ketidakseimbangan Data

Distribusi data EEG sangat tidak seimbang karena jumlah segmen non-seizure jauh lebih besar dibandingkan seizure. Oleh karena itu, undersampling hanya diterapkan pada data pelatihan, sedangkan data pengujian tetap menggunakan distribusi asli sehingga evaluasi lebih merepresentasikan kondisi nyata.

3.10 Klasifikasi SVM dan Evaluasi Performa

Model klasifikasi menggunakan Support Vector Machine dengan kernel RBF dan parameter Kernel RBF, Box Constraint 1, Kernel Scale Auto, Standardize True. Parameter standardisasi dipelajari hanya dari data pelatihan dan diterapkan pada data validasi maupun data pengujian untuk mencegah *data leakage*. Confusion matrix digunakan untuk memperoleh TP, TN, FP, dan FN.

1. Akurasi

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

2. Sensitivitas

$$\text{sensitivitas} = \frac{TP}{TP + FN} \times 100\%$$

3. Spesifisitas

$$\text{spesifisitas} = \frac{TN}{TN + FP} \times 100\%$$

4. Presisi

$$\text{presisi} = \frac{TP}{TP + FP} \times 100\%$$

5. F1-score

$$F_1 = 2 \frac{\text{Presisi} \times \text{Sensitivitas}}{\text{Presisi} + \text{sensitivitas}}$$

Jika presisi dan sensitivitas sama-sama nol, F1-score ditetapkan sebesar nol.

False Negative Rate

$$\text{FNR} = \frac{FN}{TP + FN} \times 100\%$$

False Positive Rate

$$\text{FPR} = \frac{FP}{FP + TN} \times 100\%$$

Perbedaan distribusi energi antara kelas seizure dan non-seizure dianalisis menggunakan Mann–Whitney U test dengan tingkat signifikansi $\alpha = 0,05$. Efisiensi metode dievaluasi berdasarkan waktu ekstraksi fitur, waktu pelatihan, dan waktu inferensi menggunakan MATLAB R2023b pada komputer berprosesor Intel Core i7, RAM 16 GB, dan SSD.

Tabel 4. Hasil grouped file-wise 5-fold cross-validation

Fold	File validasi	Akurasi	Sensitivitas	Spesifisitas	Presisi	F1-score	FNR	FPR	FN
1	chb01_15_data.mat	92,414%	100,000%	92,330%	12,500%	22,222%	0,000%	7,670%	0
2	chb01_18_data.mat	99,208%	93,333%	99,359%	78,873%	85,496%	6,667%	0,641%	4
3	chb01_16_data.mat	93,247%	97,059%	93,192%	17,010%	28,947%	2,941%	6,808%	1
4	chb01_03_data.mat	96,665%	85,185%	96,796%	23,232%	36,508%	14,815%	3,204%	4
5	chb01_04_data.mat	97,749%	100,000%	97,732%	25,000%	40,000%	0,000%	2,268%	0
Rata-rata	—	95,857%	95,115%	95,882%	31,323%	42,635%	4,885%	4,118%	1,80
Standar deviasi	—	2,921%	6,190%	3,008%	27,045%	24,928%	6,190%	3,008%	2,05
Standard error	—	1,306%	2,768%	1,345%	12,095%	11,148%	2,768%	1,345%	0,92

4.3 Grouped 5-Fold File-Wise Cross-Validation

Berdasarkan Tabel 8, model menunjukkan performa yang relatif konsisten pada lima *fold* dengan rata-rata akurasi 95,857% dan sensitivitas 95,115%. Variasi antar-*fold* dipengaruhi oleh perbedaan karakteristik sinyal pada setiap file, namun secara umum kombinasi fitur

IV. HASIL DAN PEMBAHASAN

4.1 Distribusi Data File-Wise

Tabel 3. Distribusi data pada evaluasi file-wise

Partisi	Non-seizure	Seizure	Total
Training sebelum balancing	11.830	165	11.995
Training setelah balancing	165	165	330
Testing tanpa balancing	2.337	62	2.399

Distribusi data pada evaluasi *file-wise* disajikan pada Tabel 7. Sebelum *balancing*, data pelatihan didominasi oleh kelas *non-seizure* dengan rasio sekitar 71,70:1, sehingga berpotensi menimbulkan bias terhadap kelas mayoritas. Oleh karena itu, random undersampling hanya diterapkan pada data pelatihan, sedangkan data pengujian tetap menggunakan distribusi asli untuk mempertahankan kondisi nyata. Strategi ini sekaligus mencegah *data leakage* karena dilakukan setelah proses *data splitting*.

4.2 Hasil File-Wise Testing

Model memperoleh akurasi 93,247%, sensitivitas 98,387%, spesifisitas 93,111%, F1-score 42,958%, dan ROC-AUC 0,9880 (Tabel 7). Sensitivitas yang tinggi dan hanya satu *false negative* menunjukkan bahwa sebagian besar *window seizure* berhasil dideteksi pada file yang tidak digunakan saat pelatihan. Sebaliknya, jumlah *false positive* yang masih cukup besar menyebabkan presisi dan *F1-score* belum optimal. Hasil ini menunjukkan bahwa evaluasi deteksi epilepsi perlu mempertimbangkan sensitivitas, *F1-score*, FPR, dan FNR, bukan hanya akurasi.

False negative rate dihitung sebagai:

$$\text{FNR} = \frac{1}{61 + 1} \times 100\% = 1,61\%$$

False positive rate dihitung sebagai:

$$\text{FPR} = \frac{161}{161 + 2.176} \times 100\% = 6,89\%$$

energi domain waktu dan PSD mampu memberikan representasi yang stabil. Meskipun demikian, hasil ini masih menggambarkan performa pada file dari pasien yang sama sehingga belum sepenuhnya merefleksikan kemampuan generalisasi antarpasien.

Tabel 5. Performa patient-wise LOSO

Pasien uji	Akurasi	Sensitivitas	Spesifisitas	Presisi	F1-score	FNR	FN
CHB01	96,418%	66,667%	97,268%	41,096%	50,847%	33,333%	15
CHB02	77,535%	75,000%	77,651%	13,314%	22,613%	25,000%	15
CHB03	95,125%	17,949%	99,306%	58,333%	27,451%	82,051%	64
CHB04	85,279%	0,935%	90,926%	0,685%	0,791%	99,065%	106
CHB05	52,551%	99,333%	47,800%	16,196%	27,850%	0,667%	1
CHB06	53,185%	21,053%	53,567%	0,536%	1,046%	78,947%	15
CHB07	74,129%	85,124%	73,198%	21,193%	33,937%	14,876%	18
CHB09	51,690%	98,810%	48,912%	10,234%	18,547%	1,190%	1
CHB10	83,403%	97,561%	82,677%	22,409%	36,446%	2,439%	2
CHB11	94,003%	8,571%	96,140%	5,263%	6,522%	91,429%	32
CHB13	95,463%	0,000%	100,000%	0,000%	0,000%	100,000%	76
Rata-rata makro	78,071%	51,909%	78,859%	17,205%	20,550%	48,091%	31,36
Standar deviasi	18,018%	42,028%	20,488%	18,329%	16,879%	42,028%	35,10

Tabel 6. Data confusion matrix per pasien

Pasien	TP	TN	FP	FN
CHB01	30	1.531	43	15
CHB02	45	1.018	293	15
CHB03	14	1.430	10	64
CHB04	1	1.453	145	106
CHB05	149	706	771	1
CHB06	4	856	742	15
CHB07	103	1.046	383	18
CHB09	83	697	728	1
CHB10	80	1.322	277	2
CHB11	3	1.345	54	32
CHB13	0	1.599	0	76

Berdasarkan Tabel 6 evaluasi patient-wise LOSO menghasilkan rata-rata akurasi 78,071% dengan sensitivitas 51,909% (Tabel 9). Penurunan performa dibandingkan evaluasi *file-wise* menunjukkan bahwa inter-subject variability masih

menjadi tantangan utama. Pada beberapa pasien model mampu mendeteksi sebagian besar *seizure*, sedangkan pada pasien lain sensitivitas menurun karena perbedaan karakteristik sinyal EEG. Kondisi ini menegaskan bahwa validasi berbasis pasien memberikan estimasi kemampuan generalisasi yang lebih realistis dibandingkan validasi berbasis file.

4.5 Analisis Generalisasi Antar Pasien

Perbedaan performa antara evaluasi file-wise dan patient-wise menunjukkan bahwa distribusi fitur masih dipengaruhi oleh karakteristik individual setiap pasien. Kombinasi fitur energi dan PSD mampu merepresentasikan perubahan aktivitas EEG dengan baik pada pasien yang sama, namun batas keputusan SVM-RBF yang dipelajari dari data pelatihan belum mampu mengakomodasi seluruh variasi antarpasien.

Temuan ini menunjukkan bahwa peningkatan kemampuan generalisasi memerlukan strategi normalisasi lintas pasien, penambahan jumlah data pelatihan, atau pendekatan pembelajaran yang lebih adaptif terhadap inter-subject variability.

Tabel 7. Perbandingan performa berdasarkan protokol evaluasi

Protokol evaluasi	Akurasi	Sensitivitas	Spesifisitas	Presisi	F1-score	FNR	FPR	ROC-AUC
Independent file-wise testing	93,247%	98,387%	93,111%	27,477%	42,958%	1,613%	6,889%	0,9880
Grouped file-wise 5-fold CV	95,857%	95,115%	95,882%	31,323%	42,635%	4,885%	4,118%	—
Patient-wise LOSO	78,071%	51,909%	78,859%	17,205%	20,550%	48,091%	21,141%	—

4.4 Hasil Patient-Wise LOSO

Perbandingan performa pada Tabel 11 menunjukkan bahwa grouped file-wise 5-fold cross-validation memberikan hasil terbaik, diikuti independent file-wise testing, sedangkan patient-wise LOSO menghasilkan performa terendah. Penurunan sensitivitas dan peningkatan false negative rate pada evaluasi LOSO menunjukkan bahwa model masih lebih efektif mengenali pola

EEG yang memiliki karakteristik serupa dengan data pelatihan dibandingkan pasien yang benar-benar baru. Oleh karena itu, hasil patient-wise LOSO digunakan sebagai indikator utama dalam mengevaluasi kemampuan generalisasi model.

4.6 Analisis Distribusi Energi dan Energy Map Kanal-Waktu

Tabel 8. Statistik energi domain waktu pada data file-wise CHB01

Statistik	Seizure	Non-seizure	Rasio seizure/non-seizure
Mean	$5,3040 \times 10^6$	$7,6987 \times 10^5$	6,89
Standar deviasi	$2,2210 \times 10^6$	$7,4080 \times 10^5$	—
Median	$5,1422 \times 10^6$	$4,5602 \times 10^5$	11,28

Rasio rata-rata energi dihitung sebagai:


$$R_{\text{mean}} = \frac{5,3040 \times 10^6}{7,6987 \times 10^5} = 6,89$$

Rasio median energi dihitung sebagai:

$$R_{\text{median}} = \frac{5,1422 \times 10^6}{4,5602 \times 10^5} = 11,28$$

Rata-rata energi sinyal *seizure* mencapai $5,3040 \times 10^6$, sedangkan rata-rata energi *non-seizure* sebesar $7,6987 \times 10^5$. Statistik energi pada Tabel 8 menunjukkan bahwa rata-rata energi kelas *seizure* lebih tinggi dibandingkan *non-seizure*. Uji Mann–Whitney U menghasilkan nilai $p = 2,1804 \times 10^{-140}$, yang menunjukkan adanya perbedaan distribusi energi yang signifikan antara kedua kelas.

Visualisasi *energy map* pada Gambar 2 memperlihatkan peningkatan energi pada beberapa kanal selama *seizure*. Representasi ini membantu menginterpretasikan distribusi energi berdasarkan kanal dan waktu, namun tidak digunakan sebagai masukan model klasifikasi maupun untuk menentukan lokasi anatomis sumber epileptogenik.




Gambar 2. *Energy map* kanal–waktu pada contoh window *seizure*. Baris menunjukkan 23 kanal EEG bipolar dan kolom menunjukkan 16 bin waktu pada rentang 0–2 detik.

4.7. Analisis ROC-AUC dan Efisiensi Komputasi

Nilai ROC-AUC sebesar 0,9880 menunjukkan kemampuan diskriminasi model yang sangat baik pada evaluasi independent file-wise testing. Namun, interpretasinya tetap harus didukung oleh sensitivitas, Perbandingan numerik akurasi tidak dilakukan secara langsung karena setiap penelitian menggunakan jumlah pasien, kanal, kelas, segmentasi, balancing, dan protokol validasi yang berbeda. Perbandingan yang hanya menggunakan akurasi dapat menghasilkan kesimpulan yang tidak adil [5], [6].

spesifisitas, F1-score, dan false negative rate. Gambar 3(a) menunjukkan bahwa model mampu mendeteksi sebagian besar aktivitas *seizure* meskipun masih menghasilkan false positive, sedangkan Gambar 3(b) mengonfirmasi kemampuan diskriminasi model pada data uji CHB01. Metode yang diusulkan juga relatif efisien karena hanya menggunakan 46 fitur sebagai masukan SVM. Penelitian sebelumnya menunjukkan bahwa implementasi deteksi epilepsi berbasis FPGA berpotensi mendukung aplikasi real-time [18]. Namun, penelitian ini masih terbatas pada evaluasi menggunakan MATLAB sehingga implementasi perangkat keras dan pengujian real-time menjadi arah penelitian selanjutnya.



Gambar 3. Evaluasi model SVM-RBF pada independent file-wise testing: (a) confusion matrix dan (b) kurva ROC menggunakan `chb01_21_data.mat`.

Dari sisi efisiensi komputasi, ekstraksi fitur merupakan tahap yang paling membutuhkan waktu karena energi dan PSD dihitung pada seluruh kanal untuk setiap *window*. Setelah fitur tersedia, pelatihan SVM-RBF memerlukan waktu sekitar 2,0701 detik, sedangkan waktu inferensi rata-rata hanya 0,10084 ms per *window*. Hasil ini menunjukkan bahwa metode yang diusulkan cukup efisien untuk analisis EEG, meskipun belum dibandingkan secara langsung dengan pendekatan *deep learning* pada kondisi pengujian yang sama.

4.8 Keterbatasan Hasil

Penelitian ini masih memiliki keterbatasan pada kemampuan generalisasi terhadap pasien baru, sebagaimana ditunjukkan oleh hasil patient-wise LOSO. Selain itu, jumlah *false positive* masih relatif tinggi dan evaluasi hanya dilakukan menggunakan CHB-MIT. Oleh karena itu, validasi pada dataset eksternal dan data klinis prospektif diperlukan untuk meningkatkan keandalan model.

V. KESIMPULAN DAN SARAN

Penelitian ini mengusulkan metode deteksi aktivitas epilepsi berbasis Support Vector Machine (SVM) dengan kernel Radial Basis Function (RBF) menggunakan kombinasi 23 fitur energi domain waktu dan 23 fitur Power Spectral Density (PSD) Welch sebagai representasi sinyal EEG multikanal CHB-MIT. Selain digunakan sebagai fitur klasifikasi, distribusi energi divisualisasikan dalam bentuk energy map berukuran 23×16 untuk mendukung interpretasi perubahan aktivitas EEG berdasarkan kanal dan waktu tanpa menjadi masukan model.

Hasil penelitian menunjukkan bahwa metode yang diusulkan memberikan performa yang baik pada independent file-wise testing dan grouped file-wise 5-fold cross-validation, serta mampu membedakan kelas seizure dan non-seizure secara signifikan berdasarkan uji Mann–Whitney. Namun, evaluasi patient-wise Leave-One-Subject-Out (LOSO) menunjukkan penurunan performa akibat inter-subject variability, sehingga kemampuan generalisasi terhadap pasien baru masih perlu ditingkatkan.

Penelitian selanjutnya disarankan memvalidasi model menggunakan dataset EEG eksternal atau data klinis prospektif, mengembangkan metode yang lebih adaptif terhadap variasi antarpasien, serta mengevaluasi implementasi pada sistem real-time untuk meningkatkan keandalan dan potensi penerapan di lingkungan klinis.

Pendanaan

Penelitian ini didanai oleh Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia melalui kontrak Nomor 285/C3/DT.05.00/PL-BARU/2026, 023/LL6/AL.04.03/PL-BARU/2026, 017/061026/PN/PTLP/SP2H/2026.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada Kementerian Pendidikan Tinggi, Sains, dan Teknologi Republik Indonesia, Lembaga Layanan Pendidikan Tinggi Wilayah VI, serta Universitas Muhammadiyah Semarang atas dukungan pendanaan dan fasilitas penelitian.

DAFTAR PUSTAKA

- [1]. A. L. Goldberger et al., "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215–e220, 2000, doi: <https://doi.org/10.1161/01.CIR.101.23.e215>.
- [2]. A. H. Shoeb, "Application of machine learning to epileptic seizure onset detection and treatment," Ph.D. dissertation, Massachusetts Institute of Technology, Cambridge, MA, USA, 2009.
- [3]. P. D. Welch, "The use of fast Fourier transform for the estimation of power spectra: A method based on time averaging over short, modified periodograms," *IEEE Trans. Audio Electroacoust.*, vol. 15, no. 2, pp. 70–73, 1967, doi: <https://doi.org/10.1109/TAU.1967.1161901>.
- [4]. C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, pp. 273–297, 1995, doi: <https://doi.org/10.1007/BF00994018>.
- [5]. R. Mourad, A. Diab, Z. Merhi, M. Khalil, and R. Le Bouquin Jeannès, "Machine and deep learning methods for epileptic seizure recognition using EEG data: A systematic review," *Brain Res.*, vol. 1864, Art. no. 149797, 2025, doi: <https://doi.org/10.1016/j.brainres.2025.149797>.
- [6]. J. Xu, K. Yan, Z. Deng, Y. Yang, J.-X. Liu, J. Wang, and S. Yuan, "EEG-based epileptic seizure detection using deep learning techniques: A survey," *Neurocomputing*, vol. 610, Art. no. 128644, 2024, doi: <https://doi.org/10.1016/j.neucom.2024.128644>.
- [7]. K. M. Tsiouris, V. C. Pezoulas, M. Zervakis, S. Konitsiotis, D. D. Koutsouris, and D. I. Fotiadis, "A long short-term memory deep learning network for the prediction of epileptic seizures using EEG signals," *Comput. Biol. Med.*, vol. 99, pp. 24–37, 2018, doi: <https://doi.org/10.1016/j.combiomed.2018.05.019>.
- [8]. Y. Wen et al., "A 65 nm/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, Art. no. 105366, 2022, doi: <https://doi.org/10.1016/j.combiomed.2022.105366>.
- [9]. S. Shanmugam and S. Dharmar, "Implementation of a non-linear SVM classification for seizure EEG signal analysis on FPGA," *Eng. Appl. Artif. Intell.*, vol. 131, Art. no. 107826, 2024, doi: <https://doi.org/10.1016/j.engappai.2023.107826>.
- [10]. Z. Zhang et al., "Cross-patient automatic epileptic seizure detection using patient-adversarial neural networks with spatio-temporal EEG augmentation," *Biomed. Signal Process. Control*, vol. 89, Art. no. 105664, 2024, doi: <https://doi.org/10.1016/j.bspc.2023.105664>.
- [11]. T. Xiao et al., "Self-supervised learning with attention mechanism for EEG-based seizure detection," *Biomed. Signal Process. Control*, vol. 87, Art. no. 105464, 2024, doi: <https://doi.org/10.1016/j.bspc.2023.105464>.
- [12]. S. Wong et al., "Channel-annotated deep learning for enhanced interpretability in EEG-based seizure detection," *Biomed. Signal Process. Control*, vol. 103, Art. no. 107484, 2025, doi: <https://doi.org/10.1016/j.bspc.2024.107484>.

- [13]. Y. Zhou, Y. Gao, Q. Li, R. Wu, A. Yang, and M.-L. Tseng, "The interpretable deep learning framework and validation for seizure detection in pediatric electroencephalography: An improved accuracy and performance analysis," *Artif. Intell. Med.*, vol. 170, Art. no. 103276, 2025, doi: <https://doi.org/10.1016/j.artmed.2025.103276>.
- [14]. T. Xiao et al., "Self-supervised learning with attention mechanism for EEG-based seizure detection," *Biomed. Signal Process. Control*, vol. 87, Art. no. 105464, 2024, doi: <https://doi.org/10.1016/j.bspc.2023.105464>.
- [15]. S. Wong et al., "Channel-annotated deep learning for enhanced interpretability in EEG-based seizure detection," *Biomed. Signal Process. Control*, vol. 103, Art. no. 107484, 2025, doi: <https://doi.org/10.1016/j.bspc.2024.107484>.
- [16]. Y. Zhou, Y. Gao, Q. Li, R. Wu, A. Yang, and M.-L. Tseng, "The interpretable deep learning framework and validation for seizure detection in pediatric electroencephalography: An improved accuracy and performance analysis," *Artif. Intell. Med.*, vol. 170, Art. no. 103276, 2025, doi: <https://doi.org/10.1016/j.artmed.2025.103276>.
- [17]. W. Zeng, M. Zhang, L. Shan, Y. Chen, Z. Li, and S. Du, "Interpretable classification of epileptic EEG signals using ALIF decomposition and attention-augmented cascaded deep neural networks," *Appl. Soft Comput.*, vol. 180, Art. no. 113211, 2025, doi: <https://doi.org/10.1016/j.asoc.2025.113211>.
- [18]. F. A. Khan, Z. Umar, A. Jolfaei, and M. Tariq, "Explainable AI for epileptic seizure detection in Internet of Medical Things," *Digit. Commun. Netw.*, vol. 11, pp. 587–593, 2025, doi: <https://doi.org/10.1016/j.dcan.2024.08.013>.
- [19]. S. S. Javidi, Q. Zhang, A. Ankeeta, M. R. Sperling, and J. I. Tracy, "High energy consumption characterizes abnormal brain state transitions in temporal lobe epilepsy," *Neurobiol. Dis.*, vol. 215, Art. no. 107089, 2025, doi: <https://doi.org/10.1016/j.nbd.2025.107089>.
- [20]. M. Shen, F. Yang, P. Wen, B. Song, and Y. Li, "A real-time epilepsy seizure detection approach based on EEG using short-time Fourier transform and GoogleNet convolutional neural network," *Heliyon*, vol. 10, Art. no. e31827, 2024, doi: <https://doi.org/10.1016/j.heliyon.2024.e31827>.
- [21]. M. S. Alam et al., "Energy-efficient FPGA implementation of an epileptic seizure detection system using a QDA classifier," *Expert Syst. Appl.*, vol. 249, Art. no. 123755, 2024, doi: <https://doi.org/10.1016/j.eswa.2024.123755>.
- [22]. J. C. Vieira et al., "Single-channel selection for epileptic seizure identification through a custom machine learning model," *Eng. Appl. Artif. Intell.*, vol. 161, Art. no. 112272, 2025, doi: <https://doi.org/10.1016/j.engappai.2025.112272>.
Journal of Electrical Technology, Vol. 11, No. 2, Juni 2026

