

# ANALISIS TIPE WAVELET COIFLETS 1 DAN COIFLETS 5 UNTUK DETEKSI PENYAKIT EPILEPSI

Siswandari Noertjahjani

Jurusan Teknik Elektro, Universitas Muhammadiyah Semarang

[siswandari@unimus.ac.id](mailto:siswandari@unimus.ac.id)

**Abstrak**— Epilepsi adalah salah satu penyakit neurologis paling umum yang mempengaruhi jutaan orang dari orang-orang di seluruh dunia. Penyakit ini selalu sangat penting di bidang biomedis, karena risiko kesehatan yang ditimbulkannya. Identifikasi epilepsi secara manual pada EEG oleh ahli saraf terlatih memakan waktu, biaya yang besar dan sangat subyektif, sehingga diperlukan metode klasifikasi otomatis epilepsi atau normal.

Untuk membedakan pola sinyal EEG epilepsi dan normal penelitian ini menggunakan mother wavelet coiflets 1 dan coiflets 5 dengan sinyal EEG pada elektroda F3 dan Fz. Segmentasi sinyal EEG 1 detik dengan frekuensi sampling 256 Hz. Sinyal diurai menggunakan dekomposisi paket wavelet 3 tingkat menjadi subband aproksimasi A1, Detail D1, Detail D2, Detail D3.

Hasil korelasi terbesar sinyal aproksimasinya mendekati 85% dengan menggunakan coiflets1 dan menunjukkan bahwa sistem prediksi epilepsi berbasis SVM yang diusulkan dapat mencapai prediksi yang kuat dengan akurasi 90 % dan Sensitivitasnya sekitar 91%.

**Kata kunci**—epilepsi, normal, EEG, sinyal,wavelet

## I. PENDAHULUAN


Epilepsi adalah salah satu penyakit neurologis yang tidak menular bersifat kronis dan disebabkan oleh aktivitas listrik sinkron abnormal neuron otak [1]. Alat untuk mendiagnosis penyakit epilepsi dengan elektroensefalografi (EEG). Sinyal EEG merekam aktivitas listrik otak, yang dapat mengungkapkan pola aktivitas listrik otak normal atau abnormal. Dalam praktik klinis, sinyal EEG dikumpulkan dari otak dengan menggunakan perangkat non-intrusif atau implan. Sinyal EEG yang direkam kemudian ditinjau dan dianalisis oleh ahli saraf terlatih untuk mengidentifikasi pola karakteristik penyakit, seperti lonjakan pra-iktal dan kejang (kejang adalah gangguan listrik yang tiba-tiba dan tidak terkontrol di otak, yang menandakan epilepsi), dan untuk menangkap informasi penyakit termasuk frekuensi dan jenis kejang. Informasi penyakit yang diturunkan dari EEG dapat digunakan untuk mendukung keputusan terapeutik. Tinjauan dan analisis manual membutuhkan banyak tenaga dan waktu, karena biasanya dibutuhkan beberapa jam untuk orang yang terlatih ahli untuk menganalisis rekaman satu hari dari satu pasien [2]. Keterbatasan ini telah memotivasi peneliti untuk mengembangkan teknik otomatis untuk mengidentifikasi

epilepsi dengan wavelet. Beberapa metode dikembangkan untuk mendeteksi kejang epilepsi, model pembelajaran mesin digunakan dengan menggabungkan akuisisi sinyal dan preprocessing Electroencephalography (EEG), ekstraksi fitur dari sinyal, dan klasifikasi antara keadaan kejang yang berbeda. Elektroensefalografi (EEG) mungkin berguna metode untuk melihat fungsi listrik nonlinier sel saraf otak; karenanya, ini adalah alat yang berharga untuk epilepsi evaluasi dan pengobatan [3]. Wavelet adalah alat analisis frekuensi-waktu yang efektif untuk dianalisis sinyal transien. Sifat ekstraksi dan representasi fiturnya bisa jadi digunakan untuk menganalisa berbagai kejadian transien dalam sinyal biomedis. Melalui Dekomposisi wavelet dari rekaman EEG, fitur transien secara akurat ditangkap dan dilokalkan baik dalam konteks waktu dan frekuensi [4][5][6]. Penelitian deteksi serangan epilepsi dengan menggunakan multiplicative extreme learning machine ekstraksi ciri yang digunakan Discrete Wavelet Transform (DWT), Covariance matrix SWD wavelet yang digunakan Daubechies 4 dengan data yang digunakan 7 set rata rata akurasi maksimal 89,82% [7].

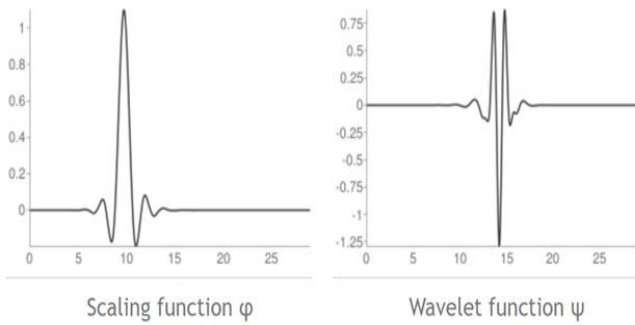
## II. DASAR TEORI

### A. Coiflets

Dibangun oleh Daubechies atas permintaan Coifman. Fungsi GS memiliki momen  $2N$  sama dengan 0 dan fungsi penyekalaan memiliki momen  $2N-1$  sama dengan 0. Kedua fungsi tersebut memiliki pendukung panjang  $6N-1$ .



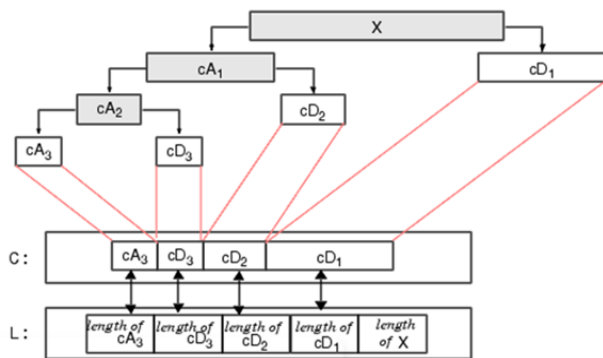
Gambar 2.1 Contoh bentuk Gelombang Singkat Coiflets1



Gambar 2.2 Contoh bentuk Gelombang Singkat Coiflets5

### B. Dekomposisi paket wavelet

Metode paket wavelet merupakan generalisasi dari dekomposisi wavelet yang memberikan jangkauan yang lebih luas untuk analisis sinyal. Pada dekomposisi wavelet sinyal dibagi menjadi komponen Aproksimasi dan detail. Komponen Aproksimasi kemudian dibagi lagi menjadi komponen aproksimasi dan detail, begitu seterusnya sampai level yang diinginkan. Pada paket wavelet, dekomposisi dilakukan pada komponen aproksimasi dan detail sekaligus. Komponen detail juga dibagi menjadi komponen detail aproksimasi dan detail detail seperti pada gambar di bawah.




Gambar 2.3 Dekomposisi wavelet

Secara matematis dekomposisi wavelet 3 tingkat dapat dituliskan :

$$\begin{aligned} X &= cA_1 + cD_1 \\ &= cA_2 + cD_2 + cD_1 \\ &= cA_3 + cD_3 + cD_2 + cD_1 \end{aligned}$$

Komponen cA1 dan cD1 didapat lewat operasi seperti pada gambar 2.3.



Gambar 2.4 Proses dekomposisi wavelet

### C. Korelasi

Dua deret sinyal  $x(n)$  dan  $y(n)$  masing-masing mempunyai energi berhingga. Korelasi silang  $x(n)$  dan  $y(n)$  adalah deret  $r_{xy}(l)$ , yang didefinisikan sebagai

$$r_{xy}(l) = \sum_{n=-\infty}^{\infty} x(n)y(n-l) \quad l = 0, \pm 1, \pm 2, \dots \quad (2.1)$$

ekuivalen dengan

$$r_{xy}(l) = \sum_{n=-\infty}^{\infty} x(n-1)y(n) \quad l = 0, \pm 1, \pm 2, \dots \quad (2.2)$$

Dimana indeks l merupakan parameter (waktu) geser (tundaan) dan subskrip xy pada deret korelasi-silang  $r_{xy}(l)$  menunjukkan deret yang akan dikorelasikan. Orde pada subskrip, dengan x mendahului y, menunjukkan arah kemana salah satu deret digeser, relatif terhadap yang lain. Jika membalik peran  $x(n)$  dan  $y(n)$  di persamaan (2.1) dan (2.2) dan membalik orde indeks xy, maka deret korelasi-silang menjadi:

$$r_{yx}(l) = \sum_{n=-\infty}^{\infty} y(n)x(n-l) \quad (2.3)$$

ekuivalen dengan

$$r_{yx}(l) = \sum_{n=-\infty}^{\infty} y(n-1)x(n) \quad (2.4)$$

Dengan melihat persamaan (2.1), (2.2), (2.3), (2.3), dapat disimpulkan

$$r_{yx}(l) = r_{xy}(-l) \quad (2.5)$$

$r_{xy}(l)$  adalah  $r_{xy}(l)$  bayangan  $l=0$ . Karena itu,  $r_{yx}(l)$  tepatnya memberikan informasi yang sama seperti,  $r_{xy}(l)$  dengan dasar kemiripan  $x(n)$  terhadap  $y(n)$ .

Dalam kasus khusus, dengan  $x(n) = y(n)$  didapat autokorelasi  $x(n)$ , yang didefinisikan sebagai deret

$$r_{xx}(l) = \sum_{n=-\infty}^{\infty} x(n)x(n-l) \quad (2.6)$$

ekuivalen dengan

$$r_{xx}(l) = \sum_{n=-\infty}^{\infty} x(n+1)x(n) \quad (2.7)$$

Sesuai dengan deret durasi-berhingga, hal itu biasa menyatakan autokorelasi, dan juga korelasi-silang, dalam batas berhingga pada penjumlahan. Khususnya, jika  $x(n)$  dan  $y(n)$  adalah deret kausal dengan panjang  $N$ ,  $x(n) = y(n) = 0$  untuk  $n < 0$  dan  $x \geq N$  deret korelasi-silang dan autokorelasi dapat dinyatakan sebagai:

$$r_{xy}(l) = \sum_{n=i}^{N-[k]-1} x(n)y(n-l) \quad (2.8)$$

dan

$$r_{xx}(l) = \sum_{n=-\infty}^{\infty} x(n)x(n-l) \quad (2.9)$$

Dimana  $i=l, k=0$  untuk  $l \geq 0$ , dan  $i=0, k=l$  untuk  $l < 0$

### III. HASIL DAN PEMBAHASAN

Dalam penelitian ini data EEG diambil dari RS Karyadi Semarang. 80 orang pasien epilepsi sebelum direkam harus berhenti obat dan perekaman dilakukan sampai beberapa hari, selama perekaman tanpa obat epilepsi. Elektroda di alat EEG ada 19 terdiri dari FP1, FP2, F7, F3, Fz, F4, F8, C3, Cz, C4, T3, T4, T5, T6, P3, P4, Pz, O1, O2. Elektroda yg ditempelkan pada kulit kepala setiap subyek menurut International 10-20 sistem penempatan elektroda. Dalam penelitian ini elektroda yang digunakan hanya didaerah frontal yaitu F3 dan Fz. Segmentasi sinyal 1 detik dengan frekuensi sampling 256 Hz. Transformasi wavelet empiris adalah konvensional yang sepenuhnya adaptif algoritma pemrosesan sinyal canggih yang digunakan untuk menguraikan nonlinier dan sinyal non-stasioner dengan memilih nilai frekuensi yang tepat untuk filter band-pass. DWT diterapkan pada sinyal EEG yang sangat kompleks untuk didekomposisi menjadi koefisien detail (D1) yang mewakili konten frekuensi tinggi dan koefisien perkiraan (A1) tentukan konten frekuensi rendah. Koefisien aproksimasi (A1) adalah didekomposisi menjadi koefisien detail (D2) dan koefisien aproksimasi (A2). Sekali lagi koefisien aproksimasi (A2) adalah didekomposisi menjadi koefisien detail (D3) dan koefisien aproksimasi (A3). Pada tabel 1 dan tabel 2 menunjukkan nilai korelasi dari aproksimasi (A3) dengan lebih tinggi menggunakan coiflets1 dibandingkan coiflets5 dan lebih tinggi dari pada D1,D2,D3. Hal ini menunjukkan aproksimasi (A3) untuk mengekstrak pita frekuensi yang paling informatif. Pada gambar 3.1 sinyal EEG epilepsi aproksimasi (A3) mempunyai amplitudo di atas 200  $\mu V$  terlihat jelas ( frekuensi

rendah). Pada gambar 3.2 terlihat korelasi yang sangat tinggi dibandingkan dengan frekuensi tinggi D1,D2,D3. Demikian pula untuk gambar 3.3 dan gambar 3.4.

TABEL 1  
UHASIL PENGUJIAN KORELASI F3


	coiflets 1	coiflets 5
$G=cD_1$	0,0034	0,00022
$T=cD_2$	0,0244	0,0156
$H=cD_3$	0,1252	0,2883
$R=cA_3$	0,8469	0,6959

TABEL 2  
UHASIL PENGUJIAN KORELASI Fz


	coiflets 1	coiflets 5
$G=cD_1$	0,0103	0,0031
$T=cD_2$	0,0211	0,0141
$H=cD_3$	0,235	0,2162
$R=cA_3$	0,8319	0,3142

Keterangan


G= nilai maksimum korelasi dari cD1 (coefficient Detail 1)  
T= nilai maksimum korelasi dari cD2(coefficient Detail 2)  
H= nilai maksimum korelasi dari cD3(coefficient Detail 3)  
R=nilai maksimum korelasi dari cA3(coefficient Aproksimasi3)



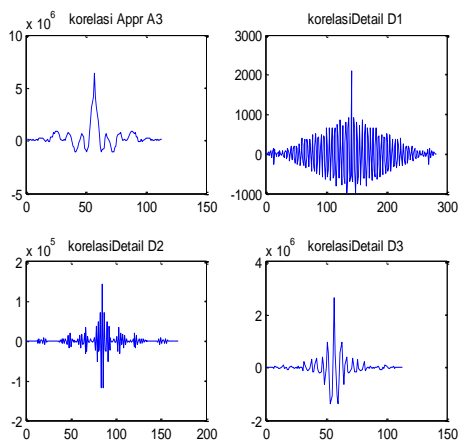
Gambar.3.1 sinyal EEG epilepsi dengan mother wavelet coiflets1



Gambar. 3.2 hasil korelasi sinyal EEG epilepsi dengan coiflets 1



Gambar.3.3 sinyal EEG epilepsi dengan mother wavelet coiflet1



Gambar. 3.4 hasil korelasi sinyal EEG epilepsi dengan coiflet 1

#### D. SVM

Support Vector Machine (SVM) adalah algoritma pembelajaran mesin yang memerlukan data latih, menentukan satu hyperplane optimal yang memisahkan dua kelas data yaitu epilepsi dan normal. Klasifikasi dilakukan dengan cara mencari hyperplane terbaik yang memisahkan data menjadi dua kelas berbeda. Data masukan yang digunakan untuk proses klasifikasi adalah 80 data (A3) yang dibagi 40 data latih (F3,Fz) dan 40 data uji (F3,Fz). Sehingga diperoleh akurasi 90% dan sensitivitasnya 91%.

#### A. REFERENSI

- [1] L.S. Vidyaratne, K.M. Iftekharuddin, Real-time epileptic seizure detection using EEG, *IEEE Trans. Neural Syst. Rehabil. Eng.* 25 (11) (2017) 2146–2156.
- [2] P. Thodoroff, J. Pineau, A. Lim, Learning robust features using deep learning for automatic seizure detection, *J. Mach. Learn. Res.* 56 (2016) 178–190, <https://doi.org/10.1162/neco.1997.9.8.1735>.
- [3] Wang, Y., Zhou, W., Yuan, Q., Li, X., Meng, Q., Zhao, X., Wang, J., 2013. Comparison of ictal and interictal eeg signals using fractal features. *International journal of neural systems* 23, 1350028.
- [4] Acharya, U.R., Sree, S.V., Alvin, A.P.C. and Yanti, R., 2012, Application of non-linear and wavelet based features for the automated identification of epileptic EEG signals, *Int J Neural Syst*, 22 (2) : 1–12.
- [5] Abdulhay Enas, 2017, Automated diagnosis of Epilepsy from EEG signals using Ensemble Learning approach, *Pattern Recognition Letters*, doi:10.1016/j.patrec.2017.05.021
- [6] Djurovic, D. and Gajic, 2014, Classification of EEG signals for detection of epileptic seizures based on wavelets and statistical pattern recognition, *Biomedical Engineering Applications, Basis and Communications*, (26), 2, 1450021.
- [7] Dazi, L. and Xie, Q., 2016, A sequential method using multiplicative extreme learning machine for epileptic seizure detection, *Journal of Neurocomputing*, 214:692–707

#### IV. KESIMPULAN

Pada aproksimasi (A3) dapat digunakan untuk mengekstrak informasi yang informatif dalam mendeteksi epilepsi dengan menggunakan coiflet1 dibandingkan dengan coiflets5. Pada frekuensi tinggi D1,D2,D3 pada sinyal EEG epilepsi mempunyai korelasi yang sangat rendah baik menggunakan coiflets1 maupun coiflets5.