

# AUTOMATIC ABNORMAL WAVES DETECTION FROM THE ELECTROENCEPHALOGRAM OF EPILEPSY WITH DWT

Siswandari Noertjahjani  
Undaris (ndarinur@yahoo.com)

## ABSTRACT

This paper proposes a feature extraction and recognition algorithm for interictal and ictal EEG signals using Discret Wavelet Transform (DWT).

Patients seizure consist 4 Males, 6 Females ages 3-35 years. Clinical status epileptic without seizure 10 Males, 18 Female, ages 10-40 years. Clinical status non epileptic 8 Male, 5 Female ages 8-42 years. Numerical data were acquired with EEG system at Karyadi hospital Semarang 2008-2013. The categorization is confirmed by Fast Fourier Transform (FFT) analysis. The dataset includes waves such as sharp, spike through DWT ( For this a mother daubechies 7, coiflets 1 and coiflets 5) of EEG records.

The experimental results show that this algorithm can achieve the sensitivity of 94.00% and pecificity of 93.75% for interictal and ictal EEGs, and the sensitivity of 92.50% and specificity of 92.75%, total accuracy of 91.21% for normal and ictal EEGs on data sets. Besides, the experiment with interictal and ictal EEGs from karyadi Hospital data set also yields sensitivity of 90.05% . specificity of 95% and total accuracy of 94.63% .

Automatic seizure detection is very helpful to review prolonged EEGs. The research carried out so far was to find the prospect of this digital signal processing on EEG waves to support the doctors work in this field.

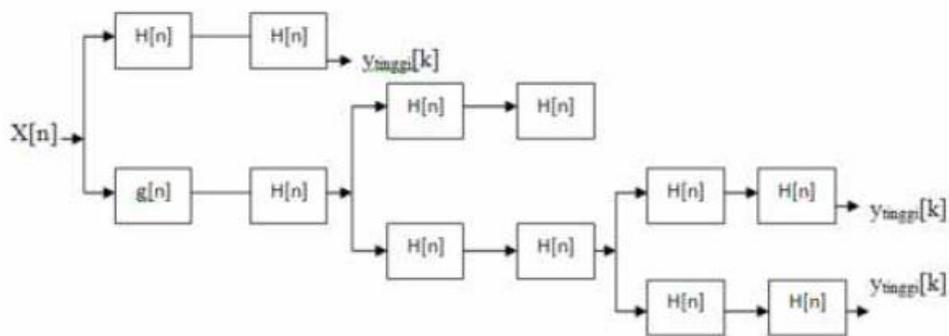
## 1. PENDAHULUAN

Epilepsi merupakan suatu manifestasi gangguan fungsi otak dengan berbagai etiologi, dengan gejala tunggal yang khas, yaitu kejang berulang lebih dari 24 jam yang diakibatkan oleh lepasnya muatan listrik neuron otak secara berlebihan dan paroksismal serta tanpa provokasi (Engel J, Pedley, 2008). Statistis Organisasi Kesehatan Dunia (WHO, 2012) menunjukkan bahwa setiap tahun antara 40 dan 70 per 100.000 orang didiagnosis epilepsi di negara maju. Angka kejadian epilepsi masih tinggi lagi terutama di Negara berkembang yang mencapai rata-rata 114 (70-190) per 100.000 penduduk per tahun (Benerjee PN, 2008). Bila jumlah penduduk di Indonesia berkisar 220 juta, maka diperkirakan jumlah penyandang epilepsi per tahunnya lebih kurang adalah 250.000. Dari banyak studi diperkirakan prevalensi epilepsi berkisar antara 0,5 – 4 %. Rata-rata prevalensi epilepsi 8,2 per 1.000 penduduk. Prevalensi epilepsi pada bayi dan anak-anak cukup tinggi, namun menurun pada dewasa muda dan pertengahan, kemudian meningkat kembali pada kelompok usia lanjut. Dengan prevalensi 0,5% dan penduduk 220 juta orang, terdapat lebih dari 1,1 juta Orang Dengan Epilepsi (ODE) di Indonesia.

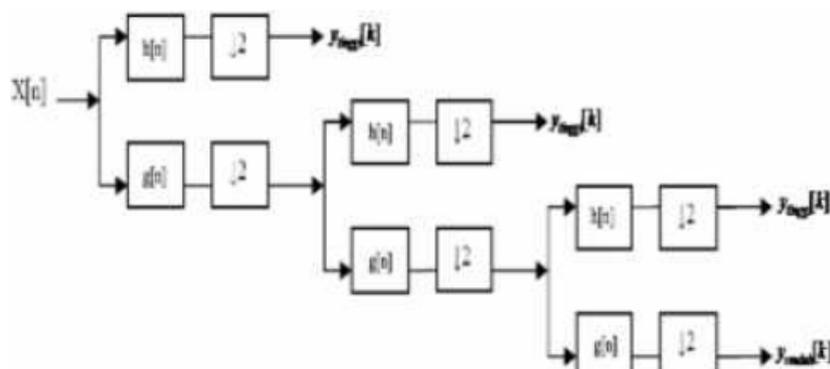
*Electroencephalogram* (EEG) telah digunakan untuk klinis diagnosis epilepsi selama beberapa dekade. Jika dibandingkan dengan metode lain seperti *Electrocorticogram* (ECOG), EEG adalah metode yang aman untuk mendeteksi aktivitas otak (A. Subasi, 2010 dan Kunjan Patel, 2009). Analisis klinis pada EEG untuk pengidentifikasi kejang adalah tepat (Jonathan J. Halforda, 2013 dan Y. Tang, D.M. Durand, 2012). Namun, analisis data EEG secara otomatis berbasis metode yang tergantung pada jenis fitur-fitur masing-masing yang dianalisis bagaimana EEG digunakan untuk klasifikasinya. Salah satu cara untuk menginterpretasi isi informasi atau pesan yang disampaikan isyarat natural, termasuk isyarat EEG, adalah dengan mengukur variasi amplitude, frekuensi, dan fase yang terdapat di dalam segmen waktu isyarat yang pendek. Pada umumnya untuk menganalisis bentuk gelombang stasioner selalu muncul metode *Fourier Transform* tetapi metode ini hanya cocok gelombang yang stasioner yaitu bersifat tetap/tidak berubah dari waktu lampau sampai takhingga. Oleh karena itu, konsep *running spectrum* (menjalankan program yang menghasilkan spektrum frekuensi) akan menjadi tidak sempurna jika akan diterapkan di dalam jendela (window) terbatas. Untuk itu perlu dipakai suatu metoda berdasar gelombang-singkat atau *Wavelet*. (Ling Guo, 2009 , Suparerk Janjarasjitt, 2010, R. Romo Vázquez, 2012).

## 2.1 Discrete Wavelet Transform

Dasar dari *DWT* dimulai pada tahun 1976 dimana teknik untuk mendekomposisi sinyal waktu diskrit ditemukan. Di dalam *CWT*, sinyal dianalisis menggunakan seperangkat fungsi dasar yang saling berhubungan dengan penskalaan dan transisi sederhana. Sedangkan di dalam *DWT*, penggambaran sebuah skala waktu sinyal *digital* didapatkan dengan menggunakan teknik filterisasi *digital*. Secara garis besar proses dalam teknik ini adalah dengan melewati sinyal yang akan dianalisis pada filter dengan frekuensi dan skala yang berbeda. Filterisasi sendiri merupakan sebuah fungsi yang digunakan dalam pemrosesan sinyal. *Wavelet* dapat direalisasikan menggunakan iterasi filter dengan penskalaan. Resolusi dari sinyal, yang merupakan rata-rata dari jumlah detail informasi dalam sinyal, ditentukan melalui filterisasi ini dan skalanya didapatkan dengan *upsampling* dan *downsampling* (*subsampling*). Sebuah sinyal harus dilewatkan dalam dua filterisasi *DWT* yaitu *highpass filter* dan *lowpass filter* agar frekuensi dari sinyal tersebut dapat dianalisis. Analisis sinyal dilakukan terhadap hasil filterisasi *highpass filter* dan *lowpass filter* di mana *highpass filter* digunakan untuk menganalisis frekuensi tinggi dan *lowpass filter* digunakan untuk menganalisis. Analisis terhadap frekuensi dilakukan dengan cara menggunakan resolusi yang dihasilkan setelah sinyal melewati filterisasi (Siddiqi, 2010). Analisis frekuensi yang berbeda dengan menggunakan resolusi yang berbeda inilah yang disebut dengan *multi-resolution analysis*, seperti yang telah disinggung pada bagian Transformasi *Wavelet*. Pembagian sinyal menjadi frekuensi tinggi dan frekuensi rendah dalam proses filterisasi *highpass filter* dan *lowpass filter* disebut sebagai dekomposisi. Proses dekomposisi dimulai dengan melewati sinyal asal melewati *highpass filter* dan *lowpass filter*. Misalkan sinyal asal ini memiliki rentang frekuensi dari 0 sampai dengan  $\omega$  rad/s. Dalam melewati *highpass filter* dan *lowpass filter* ini, rentang frekuensi di-*subsample* menjadi dua, sehingga rentang frekuensi tertinggi pada masing-masing *subsample* menjadi  $\omega/2$  rad/s. Setelah filterisasi setengah dari *sample* atau salah satu *subsample* dapat dieliminasi berdasarkan aturan Nyquist. Sehingga sinyal dapat selalu di-*subsample* separonya ( $\downarrow 2$ ) dengan cara mengabaikan setiap *sample* yang kedua. Proses dekomposisi ini dapat melalui satu atau lebih tingkatan. Dekomposisi satu tingkat ditulis dengan ekspresi matematika pada persamaan dibawah ini.



Gambar 2.1 Rekonstruksi Gelombang-Singkat Tiga Tingkat



Gambar 2.2 Rekonstruksi Gelombang Singkat Tiga Tingkat

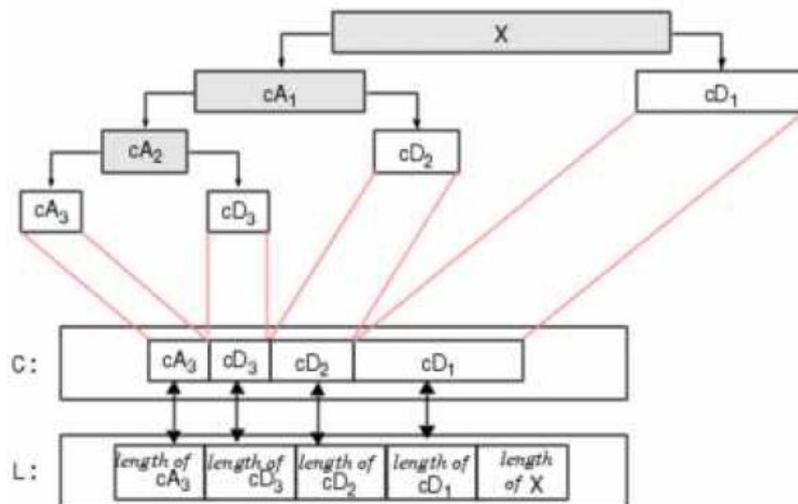
$y[k]$  tinggi dan  $y[k]$  rendah adalah hasil dari *highpass filter* dan *lowpass filter*,  $x[n]$  merupakan sinyal asal,  $h[n]$  adalah *highpass filter*, dan  $g[n]$  adalah *lowpass filter*. Untuk dekomposisi lebih

dari satu tingkat, prosedur pada rumus (2-1) dan (2-2) dapat digunakan pada masing-masing tingkatan. Contoh penggambaran dekomposisi dipaparkan pada Gambar 2.2 dengan menggunakan dekomposisi tiga tingkat.

Pada Gambar 2.2,  $y[k]$  tinggi dan  $y[k]$  rendah yang merupakan hasil dari *highpass filter* dan *lowpass filter*,  $y[k]$  tinggi disebut sebagai koefisien DWT [POL98].  $y[k]$  tinggi merupakan detail dari informasi sinyal, sedangkan  $y[k]$  rendah merupakan taksiran kasar dari fungsi penskalaan. Dengan menggunakan koefisien DWT ini maka dapat dilakukan proses *Inverse Discrete Wavelet Transform (IDWT)* untuk merekonstruksi menjadi sinyal asal.

## 2.2 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.



Gambar 2-3. Dekomposisi wavelet

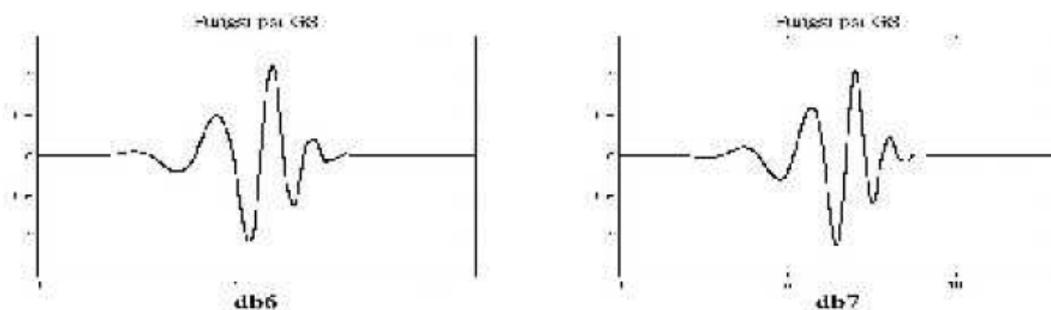
Secara matematis dekomposisi *wavelet* 3 tingkat dapat dituliskan :

$$\begin{aligned} X &= s = cA1 + cD1 \\ &= cA2 + cD2 + cD1 \\ &= cA3 + cD3 + cD2 + cD1 \end{aligned}$$

## 2.3 Jenis-jenis wavelet

### 2.3.1. Daubechies

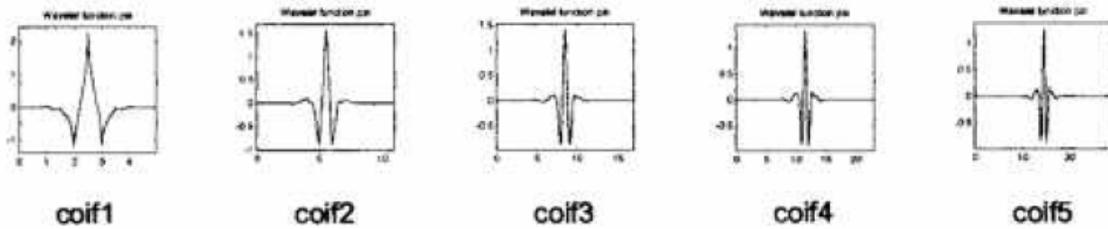
Ingrid Daubechies, salah satu dari bintang paling terang di dunia penelitian GS, menemukan apa yang disebut wilayah dukung rapat (*compactly supported*) ortonormal GS, jenis GS ortonormal yang terdukung secara mampat yang oleh karenanya analisis GS tertentu bisa diprediksikan.



Gambar 2.4 Contoh bentuk Gelombang Singkat Daubechies

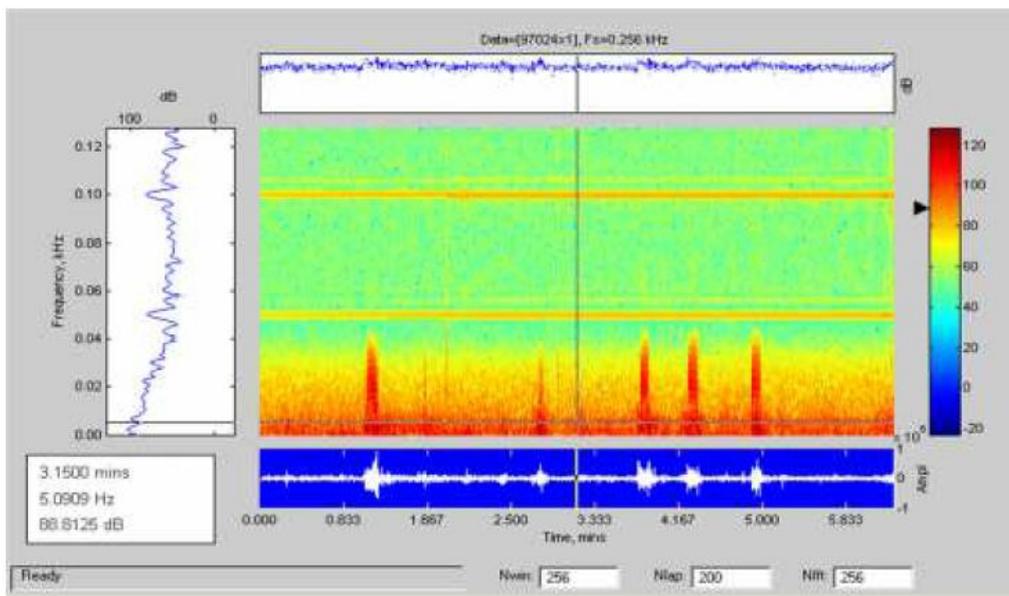
### 2.3.2. Coiflets

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  $6N-1$ . Anda bisa mengamati sifat-sifat utama dari keluarga ini dengan mengetikkan:



Gambar 2.5 Contoh bentuk Gelombang Singkat Coiflets

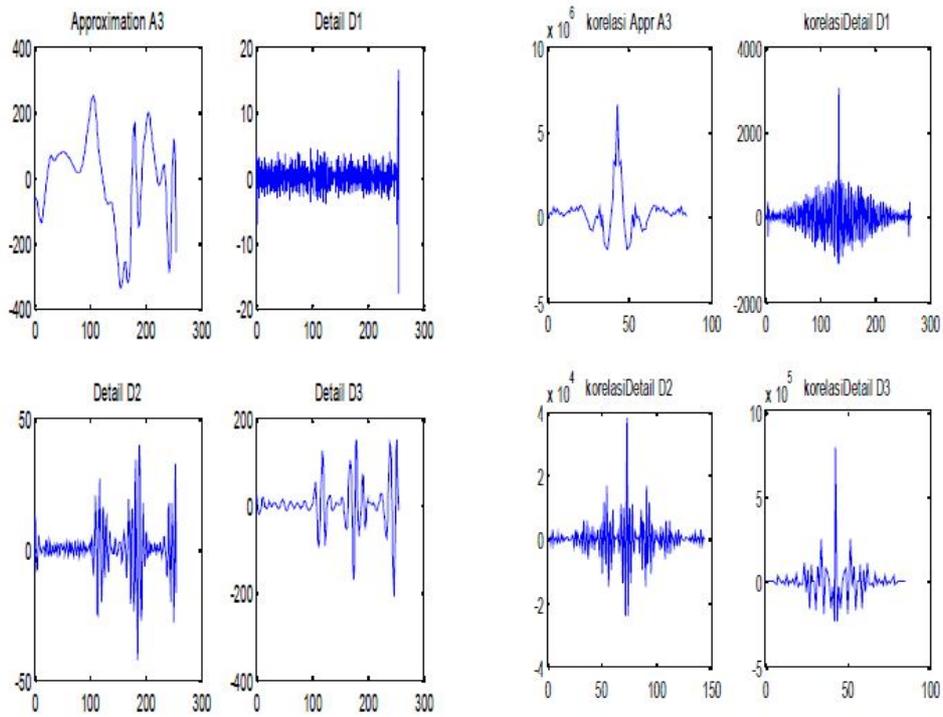
## 3.HASIL DAN ANALISA



Gambar 3.1 : Spektrogram dari sinyal FP1 – FP2 yang direkam selama 379 detik.

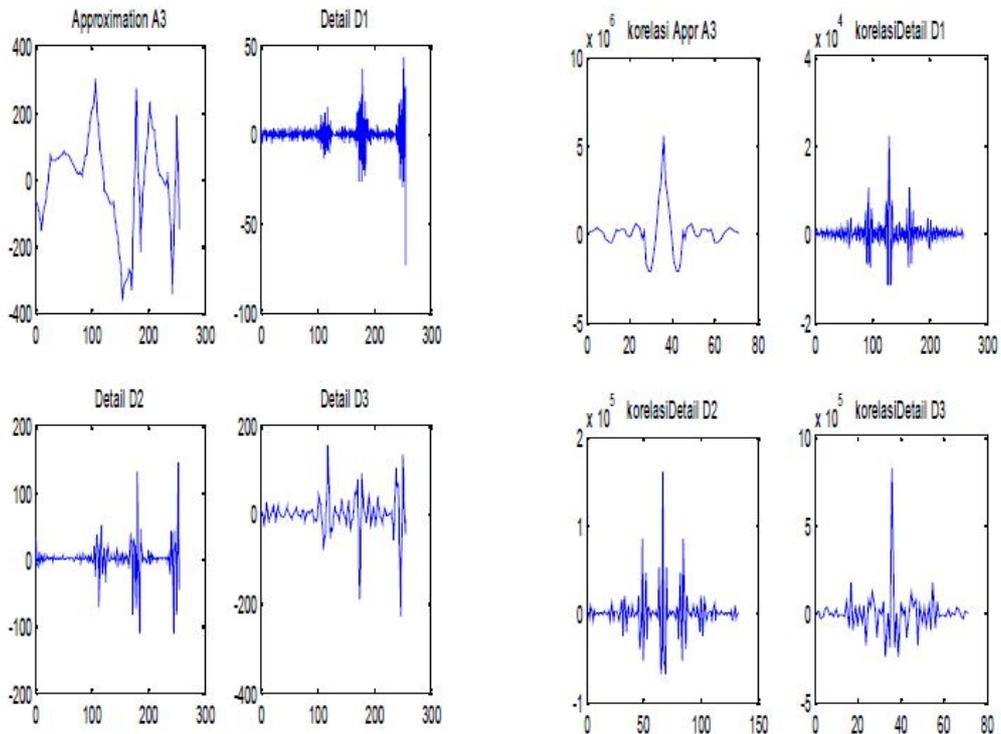
Untuk melihat spektrum daya sebuah sinyal secara lebih detail dapat dilakukan pembagian sinyal menjadi beberapa bagian, kemudian pada tiap bagian sinyal tersebut dicari PSD-nya. Misal pada sinyal FP1-FP2 yang direkam selama 6 menit,19 detik dengan frekuensi cuplik 256, akan dipisah menjadi beberapa bagian, dengan setiap bagiannya terdiri atas 256 cuplikan data, dengan data *overlapping* sebesar 200 data. Dengan menggunakan representasi citra 2D (*spectrogram*) hasilnya akan terlihat seperti pada Gambar 3.1.

Kotak Gambar paling besar merupakan representasi spektrum daya dalam bentuk citra 2D, dengan sumbu mendatar menyatakan waktu cuplikan dan sumbu vertikal menyatakan kandungan frekuensi dengan warna yang mewakili daya tiap satuan frekuensi pada waktu tertentu. Pada Gambar tersebut terlihat, bahwa, kandungan frekuensi dengan daya yang besar terjadi antara frekuensi 0 – 30 Hz (warna merah). Pada saat muncul gejala epilepsi *petit mal* spektrum daya pada daerah frekuensi tersebut menjadi semakin tinggi (merah merata). Pada Gambar juga terlihat adanya sinyal gangguan yang muncul dari sumber daya (*power supply*) dengan frekuensi 50 Hz dan 100 Hz (pita warna orange) yang muncul di seluruh sinyal. Tampak Aproksimasi (A3) pada FP1-FP2 mendekati dengan sinyal asli dan korelasi yang tinggi (6.654.100). Detail D1 ada impuls kecil konstan beraturan. Detail D2 impuls kecil konstan kemudian naik rapat turun lagi mengecil. Demikian pula dengan Detail D3 impuls kecil kemudian naik tidak runcing turun naik lagi.



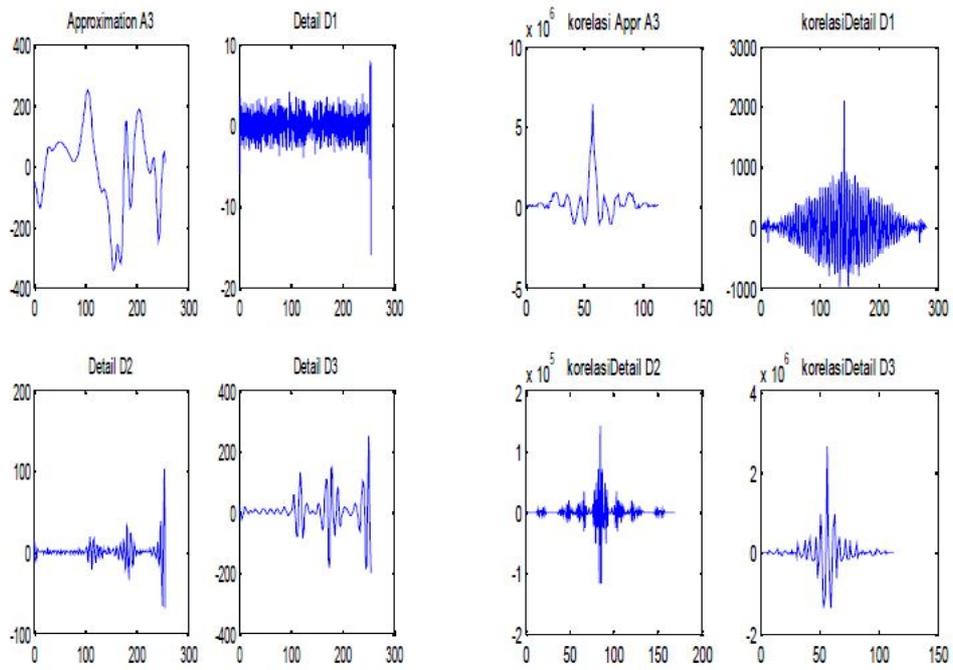
Gambar 3.2 Hasil-hasil penerapan GS Daubechies 7 sewaktu seizure

Dengan Daubechies 7 sinyal Aproksimasi A3 disamping mendekati sinyal asli juga dengan korelasi tertinggi dibandingkan dengan menggunakan Daubechies lainnya. Korelasi Aproksimasi A3 puncak runcing dan osilasi diujung kiri kanan masih muncul (belum redam). Korelasi Detail ke-1 semakin lama semakin naik, tertinggi (3.042,9).



Gambar 3.3 Hasil-hasil penerapan GS Coiflet 1 sewaktu seizure

Gambar 3.3 Coiflets1

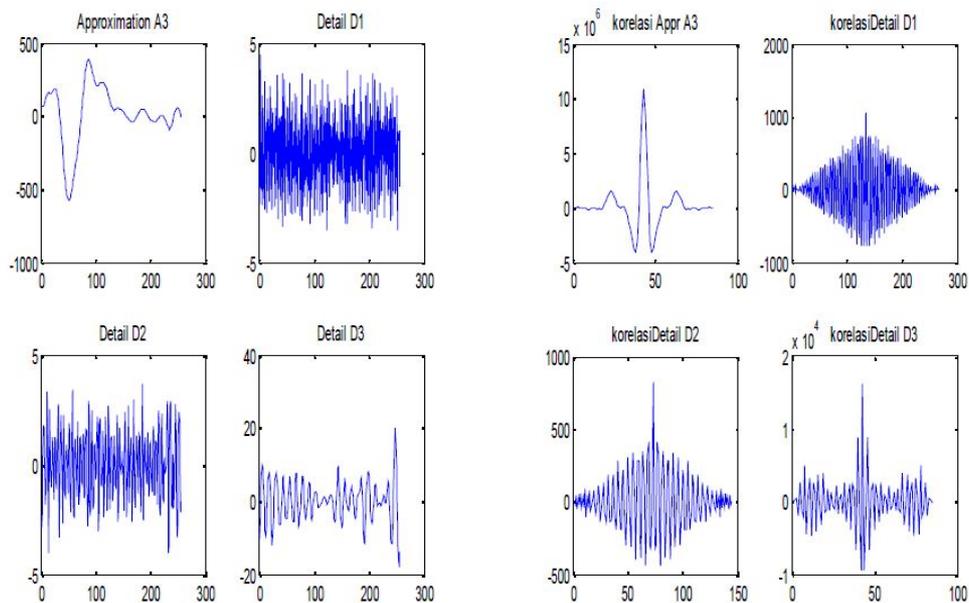


Gambar 3.4 Hasil-hasil penerapan GS Coiflet 5 sewaktu seizure

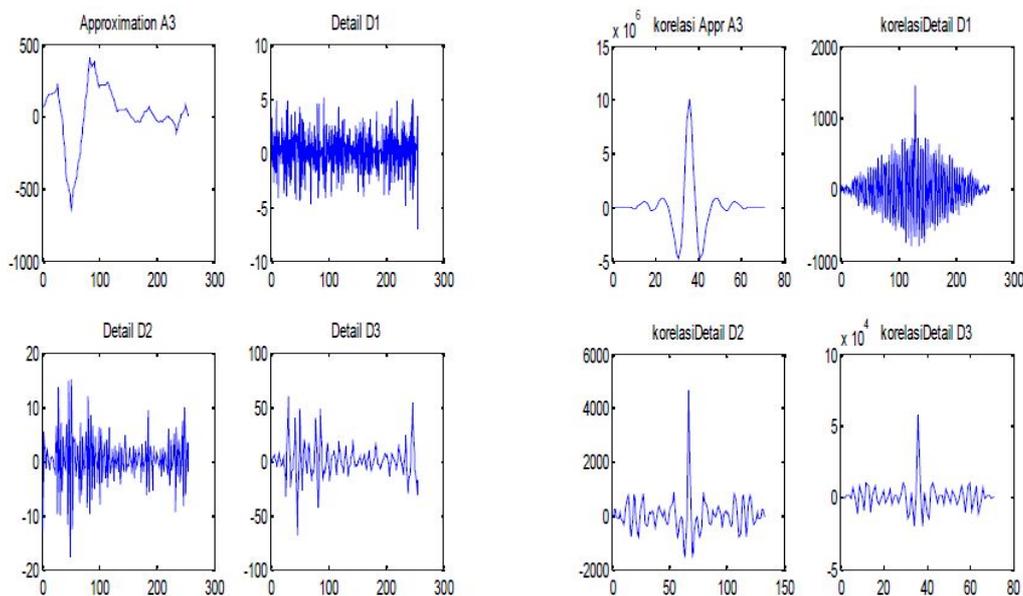
Pada Coiflets 1 sinyal Aproksimasi A3 mendekati sinyal asli dengan korelasi tinggi, tetapi pada Coiflets 5 sinyal Aproksimasi A3 agak berbeda dengan sinyal asli dan dengan korelasinya lebih tinggi dibandingkan dengan menggunakan Coiflets 1.

	$G=rr(cD1)$ max	$T=rr(cD2)$ max	$H=rr(cD3)$	$R=rr(cA3)$
dB7	3.042,9	37.942	791.420	6.654.100
Coif1	22.050	159.690	818.480	5.534.900
Coif5	2.106,1	143.510	2.655.000	6.408.200

Tabel 3.1 Korelasi Seizure



Gambar 3.5 Hasil-hasil penerapan GS Daubechies 7 sewaktu seizure



Gambar 3.6 Hasil-hasil penerapan GS Coiflets 1 sebelum seizure

#### 4. KESIMPULAN

1. Gambaran gelombang EEG yang dihasilkan dengan alat EEG yang telah ada bisa dipandang dari aspek lain, diantaranya dengan wavelet dan rapat spektral daya.
2. Studi bisa mengarah pada prediksi timbulnya gelombang seizure meski tak terlihat dengan rekaman EEG biasa.

#### DAFTAR PUSTAKA

- Benerjee PN, Hauser WA. Incidence and prevalence. In Engel J, Pedley TA. 2008, *Epilepsy A comprehensive Textbook 2nd Ed. Vol One. Philadelphia : Lippincott Williams & Wilkins ; 2008. p.45-56.*
- Engel J, Pedley TA. 2008, Introduction : *What is Epilepsy. In Engel J, Pedley TA. Epilepsy A comprehensive Textbook 2nd Ed. Vol One. Philadelphia : Lippincott Williams & Wilkins ; 2008. p.1-7.*
- Jonathan J. Halforda, Robert J. Schalkoff, Jing Zhou, Selim R. Benbadisc, 2013, *Standardized database development for EEG epileptiform transient detection: EEGnet scoring system and machine learning analysis, Journal of Neuroscience Methods 212 (2013) 308– 316*
- Ling Guo, Daniel Rivero, 2009, *Classification of EEG Signals Using Relative Wavelet Energy and Artificial Neural Networks*”, GEC.09, June 12.14, 2009, Shanghai, China. Copyright 2009 ACM 978-1-60558-326-6/09/06
- Kunjan Patel, 2009, *Power Real-Time Seizure Detection for Ambulatory EEG*, Authorized licensed use limited to: University College Dublin. Downloaded on July 28, 2009 at 05:46 from IEEE Xplore. Restrictions apply
- R. Romo Vázquez, 2012, *Blind source separation, wavelet denoising and discriminant analysis for EEG artefacts and noise cancelling*, Biomedical Signal Processing and Control 2 (2012) 389-400
- Siddiqi, 2010, *Spectral Analysis of EEG Signal by using wavelet and Harmonik Transforms*, Sharda University, School of Engineering and Technology, Istanbul.
- Subasi, M. Ismail Gursoy, 2010, *EEG signal classification using PCA, ICA, LDA and support vector machines*, Expert Systems with Applications 37 (2010) 8659–8666.
- Suparek Janjarasjitt, 2010, *Classification of EEGs Using the Wavelet-Based Scale Variance Feature*, International Journal Of Applied Biomedical Engineering Vol 3. N0.1, Thailand
- WHO, (2012), World Health Organization statistics on epilepsy. <<http://www.who.int/mediacentre/factsheets/fs999/en/index.html>> Accessed October 2012.
- Xiaofeng Liu, Xianqiang Yang, Nanning Zheng, 2012, *Automatic extracellular spike detection with piecewise optimal morphological filter*, Neurocomputing 79 (2012) 132–139.
- Y. Tang, D.M. Durand, 2012, *A tunable support vector machine assembly classifier for epileptic seizure detection*, Expert Systems with Applications 39 (2012) 3925–3938