

SISTEM DETEKSI KELAINAN JANTUNG MENGUNAKAN SINYAL ELEKTROKARDIOGRAM DENGAN METODE EMPIRICAL MODE DECOMPOSITION

Rosita Dewi¹, Bambang Hidayat², Achmad Rizal³
Fakultas Elektro dan Komunikasi, Institut Teknologi Telkom
Jln. Telekomunikasi no. 1, Ters. Buah Batu, Bojong Soang, Bandung
rositadewi89@gmail.co.id¹, bbh@ittelkom.ac.id², arl@ittelkom.ac.id³

ABSTRAK

EKG (elektrokardiogram) merupakan salah satu sinyal tubuh yang digunakan untuk mendeteksi kondisi kesehatan jantung seseorang. EKG adalah suatu rekaman aktivitas kelistrikan jantung. Apabila terdapat gangguan pada pola-pola listrik yang normal maka dapat didiagnosis berbagai kelainan jantung. Pada penelitian ini dilakukan pengenalan kelainan/penyakit jantung berdasarkan sinyal EKG menggunakan Empirical Mode Decomposition sebagai metode pengenalan sinyal EKG secara otomatis. EMD memiliki cara kerja yaitu menguraikan sinyal asli menjadi dua bagian yaitu *Independent Intrinsic Mode Function* (IMFs) dan komponen sisa. Proses penghitungannya yaitu dengan cara mengurangi jumlah sinyal yang diamati dengan *mean* (rata-rata) dari jumlah sinyal tadi. Langkah penghitungan tersebut dilakukan berulang-ulang hingga didapatkan kondisi sinyal yang stabil. Untuk klasifikasi kondisi jantung menggunakan metode *Extreme Learning Machine* (ELM). ELM merupakan jaringan syaraf tiruan *feedforward* dengan satu *hidden layer* atau lebih dikenal dengan istilah *single hidden layer feedforward neural network* (SLFN) yaitu dengan menemukan *node* yang memberikan nilai output maksimum, selanjutnya dapat menentukan hasil akhirnya. Dari 3 kelas data yang diujicobakan *Normal Sinus Rhythm* (NSR), *Congestive Heart Failure* (CHF), dan *Atrial Fibrillation* (AF)) didapat akurasi sistem sebesar 81,33 %. Oleh karena itu, metode ini cukup representatif untuk mengenali sinyal EKG yang diujicobakan.

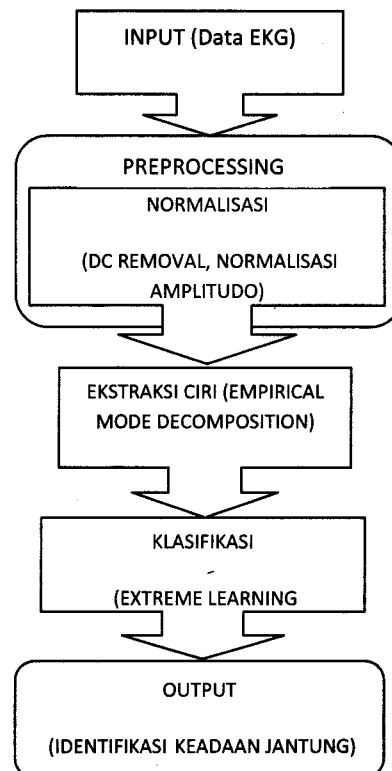
Keywords: Elektrokardiogram (EKG), *Empirical Mode Decomposition* (EMD), *Extreme Learning Machine* (ELM)

1. PENDAHULUAN

Sinyal EKG adalah sinyal listrik yang dihasilkan oleh aktifitas kelistrikan jantung. Kelainan dari fungsi jantung seseorang dapat dilihat dari rekaman sinyal EKG ini. Seorang ahli jantung menilai rekaman sinyal EKG dari bentuk gelombang, durasi, orientasi sinyal dan irama sinyal. Penilaian ini relatif subyektif, tergantung dari keahlian dokter dan kondisi pasien. Seiring dengan kemajuan teknologi elektronika dan berkembangnya teknik-teknik pengolahan sinyal digital, banyak cara dikembangkan untuk mengenali kelainan jantung secara otomatis melalui pengenalan sinyal EKG[1][4]. Pengolahan sinyal EKG yang dilakukan bisa pada domain waktu, domain frekuensi atau domain wavelet. Pada penelitian ini diujicobakan metode STFT untuk pengenalan kelainan jantung melalui sinyal EKG

2. DESAIN SISTEM

Pemodelan sistem EKG untuk penelitian ini secara sederhana dapat dilihat pada gambar 1.




Gambar 1. Pemodelan Sistem Klasifikasi EKG


2.1 Data

Data diambil dari MIT-BIH data base terdiri dari 3 kelas data yaitu *Normal Sinus Rhythm* (NSR),


Atrial Fibrillation (AF), dan Congestive Heart Failure (CHF). Data ini diambil dari lead 2 dengan frekwensi sampling 250 Hz, panjang rekaman 2-3 detik atau tiap data terdiri dari 3 gelombang QRS[4].



Gambar 2. (a) Sinyal EKG kasus *Atrial fibrillation* (b) Spektrum frekuensi *Atrial Fibrillation*



Gambar 3. (a) Sinyal EKG kasus *Congestive heart failure* (b) Spektrum frekuensi *Congestive heart failure*



Gambar 4. (a) Sinyal EKG kasus *Normal Sinus Rhythm* (b) Spektrum frekuensi *Normal Sinus Rhythm*

2.2 Preprocessing

Preprocessing yang dilakukan berupa penyeragaman data agar parameter data menjadi sama. Proses yang dilakukan adalah normalisasi berupa normalisasi amplitudo dan DC removal dari data yang didapat. DC removal dapat dilakukan dengan persamaan:

$$S(i) = S(i) - \frac{1}{N} \sum_{i=1}^N S(i) \tag{1}$$

Sedangkan normalisasi amplitudo dilakukan dengan persamaan berikut:

$$S(i) = \frac{S(i)}{S_{max}} \tag{2}$$

2.3 Empirical Mode Decomposition

Proses yang digunakan pada EMD disebut *sifting process*[2]. Konsep dasar dari EMD adalah untuk

mengidentifikasi skala waktu yang tepat yang dapat menunjukkan karakteristik fisik sinyal, dan kemudian mengubah sinyal ke mode intrinsik dengan fungsi, yang disebut sebagai Fungsi Mode intrinsik (IMF)[6].

Deteksi sinyal menggunakan EMD dapat dicari dari langkah-langkah sebagai berikut[5]:

1. Mengidentifikasi nilai ekstrim dari sinyal $x(t)$. Meliputi *upper envelope* dan *lower envelope*.
2. Menghitung data diantara *upper envelope* dan *lower envelope* yang didefinisikan sebagai m_1 (mean dari data yang berada diantara *upper envelope* dan *lower envelope*). Perbedaan antara data (sinyal awal) dan m_1 adalah komponen k_1 yang disebut juga sebagai IMF pertama

$$x(t) - m_1 = k_1 \tag{3}$$

IMF pertama dari data juga dapat dinyatakan sebagai

$$c_1 = k_1 \tag{4}$$

3. Memisahkan c_1 dari residu data dengan persamaan

$$x(t) - c_1 = r_1 \tag{5}$$


Hingga diperoleh persamaan

$$x(t) = \sum_{i=1}^n c_i + r_n \tag{6}$$

di mana sinyal didekomposisikan menjadi n -empirical modes dan residu (r_n) yang bila digabungkan lagi akan membentuk sinyal awal


4. Melakukan langkah-langkah tersebut berkali-kali hingga menghasilkan beberapa IMF yang nilainya stabil dan akhirnya menghasilkan suatu residu yang konstan atau monoton.

Berikut merupakan contoh proses pengolahan sinyal dengan EMD:



Gambar 5. Langkah-langkah mengidentifikasi IMF yang pertama

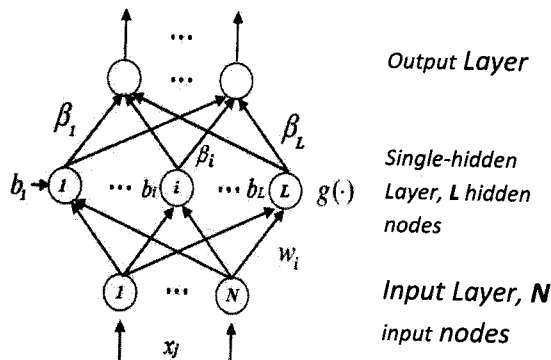
Setelah IMF pertama telah didapat, langkah-langkah berikutnya untuk mendapatkan sinyal yang stabil seperti pada gambar 6.



Gambar 6. Proses dekomposisi EMD hingga mendapatkan IMF terakhir

2.4 Extreme Learning Machine

ELM merupakan jaringan syaraf tiruan *feedforward* dengan satu *hidden layer* atau lebih dikenal dengan istilah *single hidden layer feedforward neural network* (SLFNs)[3]. Metode ELM dibuat untuk mengatasi kelemahan-kelemahan dari jaringan syaraf tiruan *feedforward* terutama dalam hal *learning speed*. Algoritma ELM tidak melatih bobot input ataupun neuron bias, tetapi untuk memperoleh bobot outputnya, ELM menggunakan *norm-least-squares solution* dan *Moore-Penrose Inverse* pada sistem linear secara umum. Dengan menemukan *node* yang memberikan nilai output maksimum, selanjutnya dapat menentukan hasil akhirnya. Berikut adalah struktur jaringan ELM.



Gambar 7. Struktur jaringan ELM

Ada tiga tahapan dalam metode pembelajaran ELM, yaitu jika diberikan data latih $\{(x_i, t_i) \mid x_i \in R^N, t_i \in R^L, i = 1, \dots, N\}$, fungsi aktivasi g , dan L node tersembunyi, maka:

1. Menentukan vector bobot input w_i dan factor pengaruh node tersembunyi ke- i $b_i, i = 1, \dots, L$.
2. Menghitung matriks keluaran pada layer tersembunyi H .
3. Menghitung bobot keluaran $\beta, \beta = H^{-1} T$

Dimana H^{-1} adalah Moore-Penrose *Generalized Inverse* pada matriks keluaran layer tersembunyi H . Setelah proses pembelajaran selesai, system akan menyimpan tiga nilai, yaitu bias node tersembunyi, bobot inpt, dan bobot output. Ketiga nilai ini akan digunakan pada tahap pengujian.

Dalam penelitian ini, parameter untuk pembelajaran ELM menggunakan:


1. Fungsi aktivasi *sigmoid*, yaitu nilai fungsi yang terletak antara 0 dan 1. Dengan persamaan:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (7)$$

2. L node tersembunyi, default nilai L adalah 400 dan 450. Nilai L akan diubah-ubah sebanyak delapan kali (pada saat 100, 150, 200, 250, 300, 350, 400 dan 450) setelah mengubah IMF pada proses ekstraksi ciri sampai mendapatkan hasil terbaik.

3. HASIL DAN DISKUSI


Database yang digunakan berisi tiga kelas kondisi jantung yaitu NSR (*Normal Sinus Rhythm*), CHF (*Congestive Heart Failure*), dan AF (*Atrial Fibrillation*) yang masing-masing akan diekstraksi ciri menggunakan EMD dengan beberapa parameter IMF. Analisis dilakukan untuk nilai IMF 2, 3, 4, 5, dan 6 yang masing-masing berisikan 30 data untuk masing-masing kelas kondisi jantung. Sehingga total data base yang dibuat yaitu sebanyak 5 buah yang masing-masing berisikan 90 data.



Gambar 8. Grafik *Normal Sinus Rhythm* (NSR) setelah dinormalisasi

Setelah dilakukan ekstraksi ciri kemudian sinyal hasil ekstraksi ciri EMD yang meliputi langkah yang pertama hingga kelima akan menunjukkan karakteristik yang berbeda. Selanjutnya

keseluruhan sinyal hasil dekomposisi akan dimasukkan ke dalam ELM. Jumlah data yang masuk pada ELM yaitu jumlah IMF dikalikan dengan jumlah sampling saat normalisasi. Sehingga pada IMF 5 prosesnya adalah 5 (nilai IMF) x 200 (jumlah neuron) = 1000 node (titik sampling). Keseluruhan node tersebut akan dilatih dengan parameter neuron yang dapat ditentukan sendiri untuk menemukan neuron yang paling optimal yakni yang dapat menghasilkan akurasi yang tertinggi. Hasil pengujian IMF 5 dengan beberapa parameter jumlah neuron yang ditampilkan pada Tabel 1.



Gambar 9. Ekstraksi ciri NSR untuk IMF 7

Tabel 1. Pengaruh nilai neuron pada hasil klasifikasi untuk nilai IMF 5

IMF	Jumlah Neuron	Akurasi (%)
5	100	35.33
	150	57.33
	200	68.67
	250	62
	300	71.33
	350	73.33
	400	75
	450	78

Neuron yang optimal untuk klasifikasi ELM yakni pada neuron 400 dan 450. Karena pada saat menggunakan neuron pada kedua data tersebut didapatkan nilai akurasi yang tertinggi yang selanjutnya akan digunakan sebagai acuan untuk pengujian IMF yang lain. Hal ini dilakukan dengan tujuan untuk menemukan nilai akurasi tertinggi yang menunjukkan performansi terbaik.

Tabel 2. Pengaruh Jumlah IMF dan neuron yang paling optimal

IMF	Jumlah Neuron	Akurasi (%)
2	400	69.33
	450	63.33
3	400	81.33
	450	74.67
4	400	73.33
	450	76.67
5	400	73.33
	450	78
6	400	80.33
	450	72.67

Tabel 3. Tabel Hasil Training Klasifikasi 3 kelas untuk IMF 3 dan Neuron 400

DATA	DIKENALI SEBAGAI		
	NSR	AF	CHF
NSR		0	1
AF	2		1
CHF	2	2	

Dari hasil pengujian yang dilakukan beberapa kali untuk parameter IMF dan neuron yang berbeda-beda, didapatkan hasil akurasi yang paling optimal yakni pada saat nilai IMF=3 dan neuron sejumlah 400.

Dari data pada Tabel 3, terdapat total 7 kesalahan pendeteksian oleh sistem. Dari hasil tersebut maka dapat disimpulkan tingkat akurasi dari sistem untuk data training adalah $82/90 \times 100\% = 91,11\%$.

Nilai akurasi paling tinggi yakni terjadi pada IMF 3 dengan jumlah neuron 400. Sehingga dapat disimpulkan bahwa performansi terbaik pada sistem ini terjadi pada kondisi tersebut.

Tabel 4. Tabel Hasil Pengujian untuk Klasifikasi 3 kelas dengan IMF=3 dan Neuron=400

DATA	DIKENALI SEBAGAI		
	NSR	AF	CHF
NSR		3	4
AF	4		5
CHF	5	7	

Dari data pada tabel 4 terdapat total 28 kesalahan pendeteksian oleh sistem. Dari hasil tersebut maka dapat disimpulkan tingkat akurasi dari sistem adalah $122/150 \times 100\% = 81,33\%$.

4. KESIMPULAN

Metode Dekomposisi EMD dan ELM mampu melakukan proses pengenalan dengan baik terhadap sinyal EKG dengan tingkat akurasi

keberhasilan mencapai 81,33% yaitu pada IMF 3 dan neuron 400. Semakin kecil jumlah IMF yang dipakai pada ekstraksi ciri EMD maka akan semakin meningkat tingkat akurasi keberhasilan pengenalan yang di dapat. Hal ini dikarenakan semakin kecil nilai IMF maka sinyal EKG yang didekomposisikan juga belum terlalu banyak sehingga ciri dari sinyal EKG masih menyerupai sinyal yang asli.

Penggunaan dekomposisi EMD sebagai ekstraksi ciri dinilai cukup baik untuk sistem klasifikasi sinyal EKG. Namun akan lebih baik lagi jika ditambahkan metoda tambahan sebagai penunjang misalnya STFT ataupun dengan mencari energi subband pada sinyal EKG.

5. DAFTAR PUSTAKA

- [1] Kinanthi, Galih W.J. 2010. Pengenalan Elektrokardiogram (EKG) Menggunakan Dekomposisi Paket Wavelet dan Support Vector Machine (SVM). Tugas Akhir, Institut Teknologi Telkom, Bandung
- [2] T.A. McMahon and F.H.S. Chiew. 2009. Issues with the Application of Empirical Mode Decomposition Analysis. The University of Melbourne, Australia.
- [3] Dwi Agustina, Irwin. 2010. Penerapan Metode Extreme Learning Machine untuk Peramalan Permintaan. Institut Teknologi Sepuluh November.
- [4] Rizal, A, Suryani, V. 2005. Pengenalan Sinyal EKG Menggunakan Dekomposisi Paket Wavelet dan K-Means Clustering. SNATI 2005. Institute Teknologi Telkom, Bandung.
- [5] *Gabriel Rilling. 2008. On Empirical Mode Decomposition And Its Algorithms. Laboratoire de Physique (UMR CNRS 5672), Ecole Normale Supérieure de Lyon 46, allée d'Italie 69364 Lyon Cedex 07. France*
- [6] Peel, M.C. 2008. Empirical Mode Decomposition. Improvement and Application. University of Melbourne. Victoria.