

# Perbandingan Skema Dekomposisi Paket Wavelet untuk Pengenalan Sinyal EKG

Achmad Rizal

**Abstract**— One indicator of a person's health is signal pattern of electrocardiogram (ECG). ECG signals are generated by the heart's electrical activity. ECG signal pattern is recognized by physicians to determine a patient's heart health. Some of the techniques were developed by researchers to automatically recognize the ECG signal. One of the most popular techniques is wavelet transform. In this study, two wavelet packet decomposition schemes for ECG signal recognition are compared to find the best one. The first scheme generates 32 features while the second scheme generates 15 features. Accuracy testing shows that the first scheme produce the best average accuracy of 94.67%, better than the second scheme. Using features selection on the first scheme, four dominant features that produce higher accuracy than using 32 features are obtained. These results indicate that the first scheme is better than the second scheme for ECG signal recognition using wavelet packet decomposition.

**Intisari**— Salah satu indikator kesehatan seseorang adalah pola sinyal elektrokardiogram (EKG). Sinyal EKG dihasilkan oleh aktivitas elektrik jantung. Pola sinyal EKG dikenali oleh dokter untuk mengetahui kesehatan jantung pasien. Beberapa teknik telah dikembangkan untuk mengenali sinyal EKG secara otomatis. Salah satu teknik yang paling populer adalah transformasi wavelet. Pada penelitian ini dibandingkan dua skema dekomposisi paket wavelet untuk pengenalan sinyal EKG. Skema pertama menghasilkan 32 ciri sedangkan skema kedua menghasilkan 15 ciri. Pengujian akurasi menunjukkan skema pertama menghasilkan akurasi rata-rata terbaik 94.67%, lebih baik dari skema kedua. Dengan teknik pemilihan ciri pada skema pertama didapat empat ciri dominan yang menghasilkan akurasi lebih tinggi dibandingkan penggunaan 32 ciri. Hasil ini menunjukkan bahwa skema pertama lebih baik dari skema kedua untuk pengenalan sinyal EKG menggunakan dekomposisi paket wavelet.

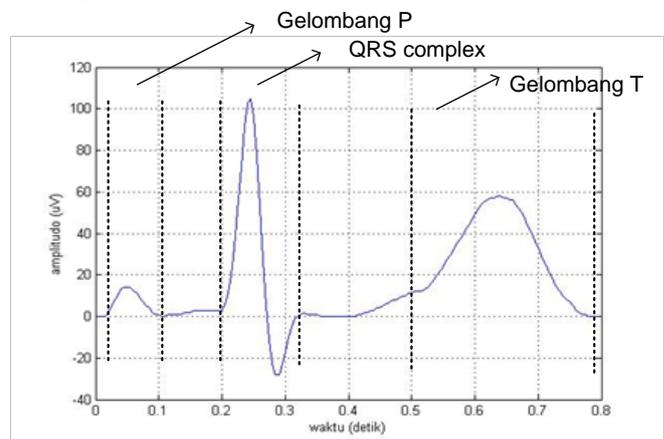
**Kata Kunci**— EKG, Dekomposisi paket wavelet, KNN, ekstraksi ciri

## I. PENDAHULUAN

Jantung merupakan salah satu organ vital dalam tubuh manusia. Jantung menghasilkan banyak sinyal yang mengindikasikan aktivitas dan tingkat kesehatan jantung, seperti suara jantung, sinyal EKG, tekanan darah dan lain-lain. Sinyal EKG merupakan salah satu sinyal jantung yang sering diamati untuk melihat kelainan pada jantung. Sinyal EKG merupakan sinyal elektrik yang dihasilkan dari aktivitas bioelektrik jantung [1].

*Program Studi S1 Teknik Elektro, Fakultas Teknik Elektro, Universitas Telkom, Jln. Telekomunikasi no 1, Bojong Soang, Bandung, 40287 INDONESIA (telp/fax: 022-7665933; e-mail: achmadrizal@telkomuniversity.ac.id)*

Sinyal EKG mencerminkan aktivitas setiap bagian jantung. Tiap bagian sinyal EKG diberi notasi P, Q, R, S, dan T [1]. Gelombang P terjadi akibat kontraksi atrium yang memompa darah menuju ventrikel. *QRS complex* terjadi sebagai akibat kontraksi ventrikel yang memompa darah ke seluruh tubuh. Amplitude *QRS complex* adalah yang paling tinggi karena energi yang dihasilkan paling besar. Gelombang T terjadi karena proses relaksasi ventrikel yaitu ketika kontraksi berakhir dan darah mulai dipompa oleh atrium ke ventrikel [2]. Contoh sinyal EKG dan pembagian gelombangnya dapat dilihat pada Gbr. 1. Setiap gelombang pada sinyal EKG mempunyai bentuk dan durasi yang standar. Setiap perubahan bentuk dan perbedaan durasi mengindikasikan kelainan yang terjadi pada jantung seseorang [3].



Gbr. 1 Contoh sinyal EKG. Terbagi atas gelombang P, QRS dan T. Tiap gelombang menyatakan aktivitas dari jantung.

Pengenalan EKG secara otomatis menjadi salah satu objek penelitian yang menarik bagi para peneliti. Salah satu teknik yang paling dikenal yaitu transformasi wavelet. Analisis wavelet banyak digunakan karena menawarkan kemudahan implementasi dan analisisnya. Transformasi wavelet digunakan untuk kompresi sinyal EKG [4][5], reduksi *noise* pada sinyal EKG [6], dan ekstraksi ciri sinyal EKG untuk pengenalan sinyal EKG [7][8][9].

Dari beberapa analisis sinyal EKG menggunakan wavelet, dekomposisi paket wavelet merupakan salah satu cara paling sederhana untuk memecah sinyal EKG menjadi *subband* yang diinginkan. Beberapa skenario dekomposisi paket wavelet ditawarkan oleh banyak peneliti analisis sinyal EKG. Brechet et.al menggunakan dekomposisi sampai level 4 untuk kompresi sinyal EKG [10]. Pada penelitian lain, terhadap sinyal EKG dilakukan dekomposisi sampai level 6 dan dihitung energi tiap *subband*-nya sebagai ciri. Dengan menggunakan jaringan syaraf tiruan sebagai *classifier* didapat

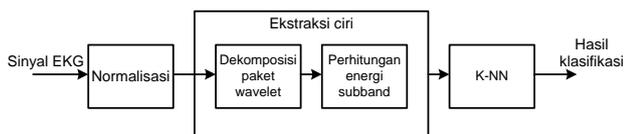
akurasi tertinggi 95.45% untuk sinyal *ventricular tachyarrytmia* [11].

Telah diusulkan juga dekomposisi paket wavelet sampai level 5 untuk ekstraksi ciri sinyal EKG dan menghasilkan akurasi di atas 90% [9]. Pada penelitian tersebut, proses klasifikasi dilakukan menggunakan *K-mean clustering* yang secara praktis tidak bisa digunakan secara *real-time*. Dekomposisi paket wavelet sampai level 5 dengan pemilihan ciri yang berbeda diusulkan pula untuk pengenalan suara paru [12]. Skema dekomposisi yang dilakukan menghasilkan 15 ciri, jauh lebih sedikit daripada skema yang diusulkan pada penelitian sebelumnya [9]. Skema dekomposisi pada penelitian [9], yang selanjutnya disebut dengan skema satu, menghasilkan 32 ciri, sedangkan skema dekomposisi pada penelitian [12] menghasilkan 15 ciri. Perbandingan kedua skema untuk pengenalan sinyal EKG belum pernah dilakukan mengingat skema dua awalnya ditujukan untuk pengenalan suara paru.

Pada penelitian ini, perbandingan kedua skema dekomposisi paket wavelet dilakukan untuk mengetahui skema mana yang lebih baik untuk pengenalan sinyal EKG. Sebagai *classifier* digunakan *K-nearest neighborhood* (KNN) dengan *5-fold cross validation* untuk meningkatkan unjuk kerja pengenalan. Pengujian pemilihan ciri menggunakan hasil penelitian yang lain juga dilakukan untuk melihat ciri dominan pada penggunaan ekstraksi ciri yang diusulkan [13]. Hasil penelitian ini diharapkan dapat menjadi rekomendasi dalam pemilihan ciri sinyal EKG menggunakan dekomposisi paket wavelet.

## II. METODOLOGI

Sistem pengenalan sinyal EKG yang dirancang ditunjukkan pada Gbr. 2. Terhadap sinyal masukan berupa sinyal EKG dilakukan proses normalisasi untuk selanjutnya dilakukan dekomposisi paket wavelet. *Subband* yang dipilih dihitung energinya dan dipakai sebagai ciri yang akan dikenali oleh KNN. Detail proses dalam tiap blok akan dijelaskan di bawah ini.



Gbr. 2 Desain sistem pengenalan sinyal EKG menggunakan dekomposisi paket wavelet dan KNN

### A. Data Percobaan

Data sinyal EKG diambil dari *database* yang tersedia di *physionet.org* [14]. Data yang sama sebagian dipakai dalam penelitian sebelumnya [9]. Sinyal EKG dengan frekuensi sampling 250 Hz dipotong-potong menjadi 2-3 siklus sehingga panjang sinyal menjadi 2-3 detik. Data terdiri atas 3 kelas data: *atrial fibrillation* (AF), *congestive heart failure* (CHF), dan *normal sinus rhythm* (NSR). Masing-masing kelas terdiri atas 50 data sehingga jumlah total data adalah 150 data.

AF merupakan kelainan takiaritmia supraventrikuler yang terjadi pada jaringan atas ventrikel [3]. Indikasi kelainan ini

adalah aktivasi atrium yang tidak terkoordinasi. Pada sinyal EKG, tampak sinyal QRS tidak terbentuk dengan jelas dan terjadinya tidak berirama.

CHF atau gagal jantung kongestif adalah kondisi ketika jantung tidak berfungsi sebagaimana mestinya. Hal ini dikarenakan jantung kehilangan kemampuan untuk memompa darah secara efektif sehingga tidak mencukupi kebutuhan tubuh [2]. Pada sinyal EKG, kelainan ini menghasilkan bentuk gelombang QRS yang khas.

NSR atau sinyal EKG normal adalah sinyal EKG yang dihasilkan oleh jantung normal. Detak jantung berirama 60-100 tiap menit dengan komponen sinyal seperti gelombang P, QRS, dan T yang lengkap [15]. Ketiga kelas data dipilih dengan alasan bahwa sinyal NSR sebagai referensi, CHF merupakan sinyal EKG dengan kelainan pada bentuk sinyal QRS sedangkan AF kelainannya berupa irama yang tidak teratur.

### B. Normalisasi

Pada sinyal EKG dilakukan proses normalisasi untuk membuat data relatif seragam. Normalisasi pertama yang dilakukan adalah penghilangan komponen DC. Pada sinyal  $s(i)$  sepanjang  $N$ , proses yang dilakukan adalah seperti pada (1).

$$s(i) = s(i) - \frac{1}{N} \sum_{i=1}^N S(i), \quad i = 1, 2, \dots, N \quad (1)$$

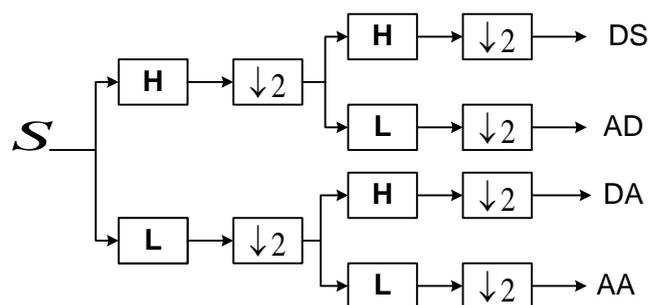
Selanjutnya pada sinyal EKG dilakukan normalisasi amplitude. Proses normalisasi amplitude dapat dijelaskan dengan (2).

$$s(i) = \frac{s(i)}{\max|s(i)|} \quad (2)$$

Dengan proses normalisasi, perbedaan pada sinyal akibat proses perekaman dan pergeseran nilai nol akibat derau bisa diminimalkan.

### C. Dekomposisi Paket Wavelet

Pada penelitian ini digunakan dua skema dekomposisi paket wavelet untuk ekstraksi ciri pada sinyal EKG. Secara grafis proses dekomposisi paket wavelet dapat dilihat pada Gbr. 3.



Gbr. 3 Dekomposisi paket wavelet level 2 pada sinyal S. H menunjukkan HPF sedangkan L menunjukkan LPF sementara  $\downarrow 2$  menunjukkan proses downsampling 2. Notasi A menyatakan aproksimasi atau pendekatan (keluaran LPF) sedangkan D menyatakan detail (keluaran HPF)

Sinyal S dimasukkan ke dalam LPF dan HPF sesuai dengan *mother wavelet* yang dipakai kemudian di-*downsampling* 2.

Masing-masing akan menghasilkan komponen aproksimasi dan komponen detail [16]. Pada level 2, proses yang sama dilakukan pada komponen detail dan komponen aproksimasi. Untuk level dekomposisi sebanyak  $n$  akan dihasilkan  $2^n$  *subband*.

Pada penelitian ini dilakukan dekomposisi paket wavelet orde 5 menggunakan wavelet Daubechies1 dengan dua skema yang berbeda. Proses tiap skema dekomposisi dapat dijelaskan sebagai berikut.

1) Skema 1

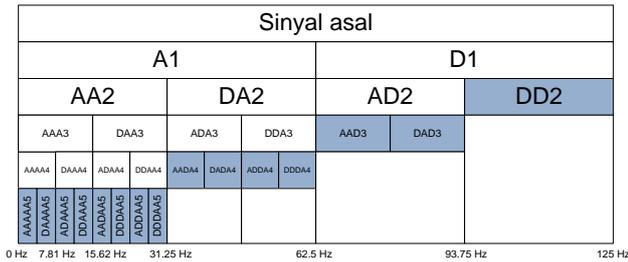
Pada skema 1, sinyal EKG didekomposisi paket wavelet level 5 sehingga akan menghasilkan  $2^5 = 32$  *subband*. Keseluruhan *subband* diambil sebagai ciri dengan menghitung energi *subband* dengan perhitungan seperti pada (3).

$$Eb(n) = \frac{1}{M} \sum_{k=1}^M S_n(k)^2 \tag{3}$$

dengan  $S_n$  adalah koefisien wavelet pada *subband* ke- $n$  dengan  $n = 1, 2, \dots, 32$  dan  $Eb(n)$  adalah energi *subband* ke- $n$ . Dengan frekuensi sampling,  $fs = 250$  Hz maka lebar pita tiap *subband* adalah  $(fs/2) : 32 = 3,90625$ Hz. Pembagian lebar pita 3,90625 Hz dianggap mencukupi untuk melihat komponen sinyal dalam sinyal EKG

2) Skema 2

Pada skema 2, sinyal EKG didekomposisi sampai level 5. Perbedaan dengan skema 1 adalah adanya pemilihan *subband* sebagai ciri. *Subband* yang dipilih seperti ditunjukkan pada Gbr. 4.



Gbr. 4 Pengambilan *subband* sebagai ciri pada skema 2. Skema dekomposisi diambil dari [12] dengan mengubah frekuensi sampling sesuai dengan sinyal EKG (250 Hz) sehingga menghasilkan lebar pita *subband* yang berbeda

Pada Gbr. 4 terlihat bahwa pada frekuensi di bawah 31,25 Hz diambil delapan *subband* dengan lebar pita masing-masing 3,90625 Hz, pada frekuensi antara 31,25 Hz hingga 62,5 Hz diambil empat *subband* selebar 7,8125 Hz, pada frekuensi antara 62,5 Hz hingga 93,75 Hz diambil dua *subband* selebar 15,625 Hz dan pada rentang frekuensi 93,75 Hz hingga 125 Hz hanya diambil satu *subband* dengan lebar pita 31,25 Hz. Skema pengambilan *subband* secara bertahap seperti ini didasari pertimbangan bahwa informasi terbesar pada sinyal EKG tersimpan pada frekuensi di bawah 40 Hz. Hal inilah yang membuat pada teknik *monitoring ECG* lebar pita yang diizinkan sampai 40 Hz, sementara untuk *clinical ECG* lebar pita pengamatan harus 100 Hz [1].

Selanjutnya energi tiap *subband* dihitung menggunakan (3). Dengan skema ini akan diperoleh 15 ciri yang akan digunakan untuk proses pengenalan.

D. K-Nearest Neighbour (KNN)

Untuk proses klasifikasi digunakan KNN sebagai *classifier*. KNN termasuk dalam *lazy learner* karena tidak memerlukan adanya proses pelatihan. Pada KNN, data masukan dihitung jaraknya dengan seluruh data latih. Setelah itu diambil sejumlah K data latih dengan jarak terdekat. Data uji akan dikategorikan sesuai dengan kelompok data terbanyak dari sejumlah K data terdekat [17]. Pada penelitian ini digunakan nilai K=1, 3 dan 5. Pengukuran jarak yang digunakan dalam penelitian ini adalah sebagai berikut.

1) Jarak Euclidean

Misal diketahui dua buah vektor baris  $x_i = x_{i1}, x_{i2}, \dots, x_{in}$  dan  $x_j = x_{j1}, x_{j2}, \dots, x_{jn}$  maka jarak Euclidean keduanya adalah seperti pada (4)

$$d(i, j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{in} - x_{jn})^2} \tag{4}$$

2) Jarak city block

Jarak *city block* dihitung seperti pada (5).

$$d(i, j) = |x_{i1} - x_{j1}| + |x_{i2} - x_{j2}| + \dots + |x_{in} - x_{jn}| \tag{5}$$

3) Jarak cosine

Dengan  $x'$  adalah transpose dari  $x$  dan  $|x|$  adalah magnitudo  $x$ , jarak *cosine* dapat dihitung dengan (6).

$$d(i, j) = 1 - \frac{x_i \cdot x_j'}{|x_i| \cdot |x_j|} \tag{6}$$

4) Jarak correlation

Dengan  $\bar{x}$  adalah nilai rata-rata  $x$ , jarak *correlation* dapat dihitung menurut (7).

$$d(i, j) = 1 - \frac{(x_i - \bar{x}_i) \cdot (x_j - \bar{x}_j)'}{|x_i| \cdot |x_j|} \tag{7}$$

E. N-Fold Cross Validation

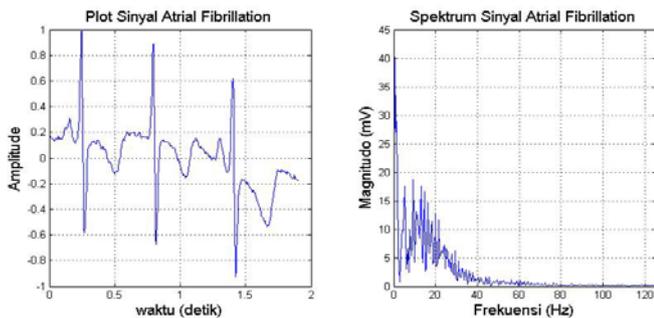
Untuk menjaga agar variasi hasil pengenalan tetap rendah, terkait dengan pemilihan data latih dan data uji, dilakukan *N-fold cross validation*. Pada teknik ini, data dibagi sejumlah N *dataset*. *Dataset* ke-1 digunakan sebagai data uji sedangkan *dataset* ke-2, 3, ..., N digunakan sebagai data latih. Kemudian, hasil akurasi dicatat. Selanjutnya proses diulangi dengan *dataset* ke-2 sebagai data uji dan *dataset* ke-1, 3, ..., N digunakan sebagai data latih. Proses diulangi sampai sejumlah N kali dan akurasi total adalah jumlah akurasi dibagi N [17]. Pada penelitian ini digunakan N = 5 mengingat jumlah data masing-masing kelas 50 buah.

III. HASIL DAN DISKUSI

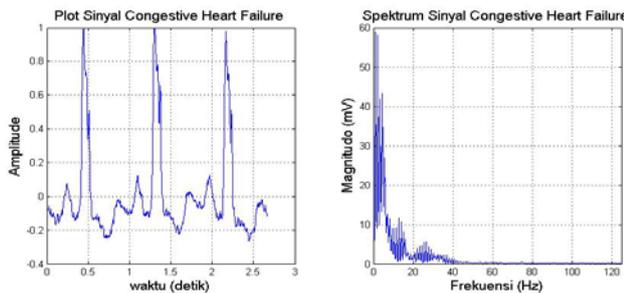
Dari pengujian yang dilakukan, diperoleh hasil-hasil yang akan dijelaskan pada bagian berikut ini.

A. Hasil Ekstraksi Ciri

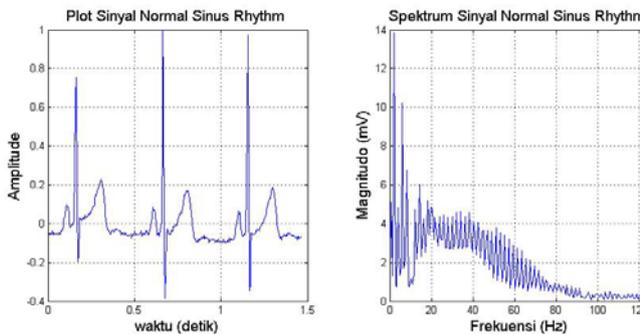
Sinyal EKG yang menjadi sinyal masukan dalam sistem yang dibuat ditunjukkan pada Gbr. 5, Gbr. 6, dan Gbr. 7. Seperti telah dijelaskan pada bagian sebelumnya, perbedaan ketiga jenis sinyal EKG ini adalah pada irama, bentuk gelombang utama dan yang lebih penting adalah sebaran informasi pada domain frekuensi. Seperti pada Gbr. 5, Gbr. 6, dan Gbr. 7 terlihat bahwa bentuk spektrum ketiga jenis sinyal EKG ini berbeda. Perbedaan ini yang akan dikuantisasi menggunakan dekomposisi paket wavelet.



Gbr. 5 Plot sinyal *Atrial fibrillation* dan spektrumnya. Terlihat bahwa sinyal tidak reguler dan bentuk QRS tidak nampak jelas. Pada spektral terlihat bahwa informasi utama sinyal terletak di bawah frekuensi 40 Hz

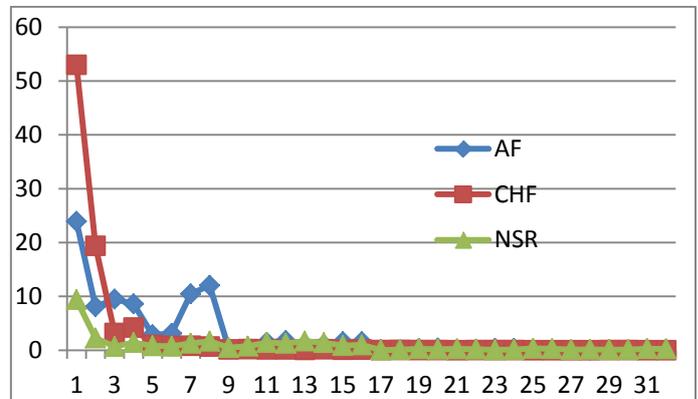


Gbr. 6 Plot sinyal *Congestive Heart Failure* dan spektrum frekuensinya. Bentuk QRS terlihat berubah sebagai efek kekuatan memompa darah pada ventrikel yang berkurang



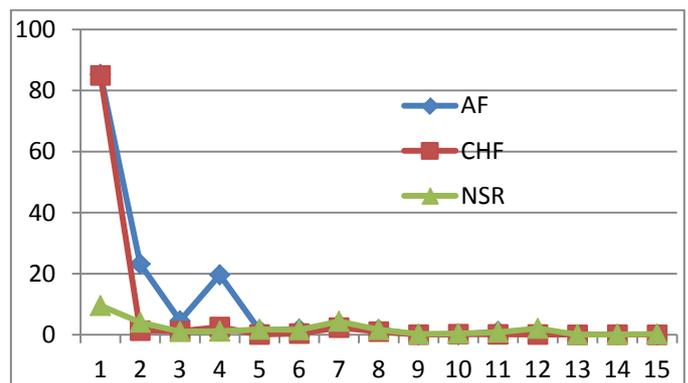
Gbr. 7 Plot sinyal *Normal Sinus Rhythm* dan spektrum frekuensinya. Gelombang QRS terlihat sempurna sedangkan informasi sinyal lebih melebar sampai frekuensi 60 Hz.

Hasil ekstraksi ciri menggunakan masing-masing skema dapat dilihat pada Gbr. 8 dan Gbr. 9. Pada Gbr. 8 jumlah ciri yang diperoleh adalah 32 dengan resolusi yang sama besar. Jika dibandingkan dengan spektrum frekuensi sinyal pada Gbr. 5, Gbr. 6 dan Gbr. 7, dapat diambil hipotesis bahwa informasi dari ciri 17 sampai dengan 32 tidak terlalu signifikan sehingga bisa direduksi atau resolusinya dibuat lebih kasar seperti yang dilakukan pada skema 2.



Gbr. 8 Hasil dekomposisi paket wavelet skema 1. Sumbu x menunjukkan ciri ke-n sedangkan sumbu y menunjukkan magnitudo energi tiap *subband*. Ciri ke-1 sampai 16 menunjukkan frekuensi di bawah 62,5 Hz sedangkan ciri ke-17 sampai 32 menunjukkan frekuensi 62,5-125 Hz.

Pada Gbr. 9 terlihat bahwa jumlah ciri hasil dekomposisi dengan skema 2 hanya 15. Ciri yang dianggap paling signifikan adalah ciri 1 hingga 8 yang berkorelasi dengan *subband* pada frekuensi 0 sampai 31,25 Hz. Ciri 1 hingga 8 mirip dengan ciri 1 hingga 8 pada skema 1. Jika pada rentang 31,25 Hz sampai 62,5 Hz pada skema 1 dibuat menjadi 8 ciri, maka pada skema 2 hanya menghasilkan 4 ciri. Hal yang lebih kontras terjadi pada rentang 62,5 Hz sampai 125 Hz yang menghasilkan 16 ciri pada skema 1 menjadi hanya 3 ciri pada skema 2. Skema 2 dirancang untuk mengurangi jumlah ciri pada dekomposisi paket wavelet pada skema 1. Efektivitas skema 2, dibandingkan dengan skema 1 dapat dilihat pada bagian berikut.



Gbr. 9 Hasil dekomposisi paket wavelet skema 2. Sumbu x menunjukkan ciri ke-n sedangkan sumbu y menunjukkan magnitudo energi tiap *subband*. Ciri ke-1 sampai 12 menunjukkan frekuensi di bawah 62,5 Hz sedangkan ciri ke-13 sampai 15 menunjukkan frekuensi 62,5-125 Hz.

**B. Akurasi Sistem**

Hasil pengujian akurasi untuk tiap skema dengan berbagai pengukuran jarak dan nilai K ditunjukkan oleh Tabel I dan Tabel II. Akurasi rata-rata tertinggi pada skema 1 dicapai untuk pengukuran jarak Euclidean dan nilai K = 1 dengan tingkat akurasi 94,67%. Jika dianggap 30 data yang dikenali, berarti hanya ada 1 data yang salah.

Sementara itu untuk skema 2, akurasi data-rata tertinggi adalah 82% dengan jarak *city block* dan K = 1 dan jarak *cosine* dengan K = 3. Dengan melihat hasil ini dapat dikatakan bahwa dekomposisi paket wavelet dengan skema 1 menghasilkan akurasi yang lebih baik dibandingkan dengan skema 2. Hal ini berarti, meskipun secara teori informasi pada sinyal EKG pada frekuensi di atas 62,5 Hz relatif tidak signifikan, tetapi mampu membedakan jenis sinyal EKG yang satu dengan yang lain. Untuk itu penggunaan 32 *subband* pada skema 1 terbukti mampu menghasilkan akurasi yang sangat tinggi.

TABEL I  
AKURASI RATA-RATA SKEMA 1 DENGAN BERBAGAI PENGUKURAN JARAK

Jarak	Euclidean			Cityblock		
	K=1,	K=3	K=5	K=1,	K=3	K=5
Nilai K	K=1,	K=3	K=5	K=1,	K=3	K=5
Akurasi (%)	94.67	94	93.33	93.33	93.33	94
Jarak	Cosine			Correlation		
	K=1,	K=3	K=5	K=1,	K=3	K=5
Nilai K	K=1,	K=3	K=5	K=1,	K=3	K=5
Akurasi (%)	86	84	85.33	84	80	82.67

TABEL II  
AKURASI RATA-RATA SKEMA 2 DENGAN BERBAGAI PENGUKURAN JARAK

Jarak	Euclidean			Cityblock		
	K=1,	K=3	K=5	K=1,	K=3	K=5
Nilai K	K=1,	K=3	K=5	K=1,	K=3	K=5
Akurasi (%)	78.67	78	78	82	79.33	80.67
Jarak	Cosine			Correlation		
	K=1,	K=3	K=5	K=1,	K=3	K=5
Nilai K	K=1,	K=3	K=5	K=1,	K=3	K=5
Akurasi (%)	78.67	81.33	82	76,67	77.33	78.67

**C. Sensitivity dan Specificity**

Parameter lain yang digunakan untuk mengukur unjuk kerja sistem pengenalan sinyal biologi adalah *specificity* dan *sensitivity*. *Specificity* didefinisikan sebagai jumlah data sehat yang dikenali sebagai sehat dibagi jumlah data sehat keseluruhan [18], sementara *sensitivity* dirumuskan sebagai jumlah data patologis yang dikenali sebagai data patologis dibagi keseluruhan data patologis. Secara matematis *specificity* dan *sensitivity* dirumuskan sebagai berikut:

$$Specificity = \frac{True\ Negative}{False\ Positive + True\ Negative} \quad (8)$$

$$Sensitivity = \frac{True\ Positive}{False\ Negative + True\ Positive} \quad (9)$$

Dengan *True Negative* (TN) adalah jumlah data sehat yang dikenali sebagai sehat, *False Positive* (FP) adalah jumlah data sehat yang dikenali sebagai patologi. *True Positive* (TP) adalah jumlah data patologis yang dikenali sebagai data patologis, sedangkan *False Negative* (FN) adalah jumlah data patologis yang dikenali sebagai data sehat.

Analisis *specificity* dan *sensitivity* pada penelitian ini hanya akan dilakukan pada kondisi dengan akurasi tertinggi. Pada skema 1, akurasi rata-rata tertinggi dicapai pada jarak Euclidean dan K = 1. Akurasi lengkap tiap dataset dapat dilihat pada Tabel III. Tampak bahwa akurasi tertinggi mencapai 100% untuk *dataset 4* dan *dataset 5*. Hal ini secara otomatis menunjukkan bahwa nilai *specificity* dan *sensitivity* mencapai 100%.

TABEL III  
AKURASI TIAP DATASET UNTUK SKEMA 1 DENGAN JARAK EUCLIDEAN

	Euclidean		
	K=1,	K=3	K=5
Dataset 1	86.67	83.33	83.33
Dataset 2	93.33	96.67	93.33
Dataset 3	93.33	90.00	90.00
Dataset 4	100.00	100.00	100.00
Dataset 5	100.00	100.00	100.00

Pada skema 2, akurasi rata-rata tertinggi dicapai saat jarak *cityblock* dengan K = 1. Akurasi tiap *dataset* untuk jarak *cityblock* pada skema 2 dapat dilihat pada Tabel IV. Akurasi tertinggi dicapai oleh *dataset 2* dan *dataset 3*. Penghitungan *specificity* dan *sensitivity* dapat dilakukan dengan membuat *confusion matrix* seperti pada Tabel V dan Tabel VI.

TABEL IV  
AKURASI TIAP DATASET UNTUK SKEMA 2 DENGAN JARAK CITYBLOCK

	Cityblock		
	K=1,	K=3	K=5
Dataset 1	70.00	63.33	60.00
Dataset 2	93.33	86.67	93.33
Dataset 3	93.33	90.00	90.00
Dataset 4	86.67	90.00	93.33
Dataset 5	66.67	66.67	66.67

TABEL V  
CONFUSION MATRIX AKURASI DATASET 2 UNTUK SKEMA 2 DENGAN JARAK CITYBLOCK

Data	Dikenali sebagai		
	AF	CHF	NSR
AF	10	0	0
CHF	2	8	0
NSR	0	0	10

TN = 10  
TP = 20  
FP = 0  
FN = 0

TABEL VI  
CONFUSION MATRIX AKURASI DATASET 3 UNTUK SKEMA 2 DENGAN JARAK CITYBLOCK

Data	Dikenali sebagai		
	AF	CHF	NSR
AF	8	2	0
CHF	0	10	0
NSR	0	0	10

$TN = 10$   
 $TP = 20$   
 $FP = 0$   
 $FN = 0$

Pada Tabel V dan Tabel VI terlihat bahwa sekalipun akurasi nya 93,33%, nilai *specificity* dan *sensitivity* pada skema 2 mencapai 100%. Kesalahan pengenalan hanya berupa pertukaran data CHF dikenali sebagai AF, dan sebaliknya.

Secara umum dapat dikatakan bahwa skema 1 lebih baik dalam hal akurasi, tetapi menghasilkan nilai yang sama dengan skema 2 pada pengukuran *specificity* dan *sensitivity*. Kelebihan skema 2 adalah jumlah ciri yang lebih sedikit.

#### D. Pemilihan Ciri Dominan pada Skema 1

Pada penelitian terdahulu telah diuji pemilihan ciri pada dekomposisi paket wavelet skema 1 menggunakan metode *sequential forward selection* (SFS) dan *sequential backward selection* (SBS) [13]. SFS adalah teknik mencari ciri dominan dengan menguji ciri satu persatu dan menambah ciri berikutnya sampai terdapat penurunan akurasi. Penambahan ciri akan dihentikan jika penambahan ciri tersebut membuat akurasi menurun [19]. Sedangkan SBS adalah teknik mencari ciri dominan dengan menggunakan semua ciri dan menghilangkan satu demi satu ciri yang tidak mempengaruhi akurasi. Jika pada SFS ciri mula-mula adalah himpunan kosong, pada SBS ciri mula-mula adalah keseluruhan ciri [19].

Menggunakan teknik SFS diperoleh ciri dominan yakni ciri ke-1, 5, 9 dan 13. Dengan teknik SBS diperoleh ciri dominan adalah ciri ke-1, 2, 4, 13, 18, 21, 22, 28, 29, 30, 31, dan 32 [13]. Pada penelitian tersebut jumlah data hanya 30 tiap kelas data dan pembagian data latih dan data uji adalah 50-50. Untuk itu, pada penelitian ini ciri dominan yang dihasilkan akan diuji menggunakan data yang lebih banyak dan KNN dengan *5-fold cross validation*.

Tabel VII dan Tabel VIII menunjukkan akurasi rata-rata ciri yang dipilih menggunakan metode SFS dan SBS. Akurasi tertinggi 96,67 dengan jarak dan nilai K yang berbeda. Jika dibandingkan secara langsung, sekalipun menghasilkan akurasi yang sama, metode SFS lebih baik daripada metode SBS karena ciri yang dihasilkan lebih sedikit.

Ciri yang dihasilkan teknik SFS dan SBS merupakan ciri yang dipilih dari skema 1. Terlihat bahwa hanya ada 2 ciri yang juga dimiliki oleh skema 2 yaitu ciri ke-1 dan ke-5 untuk hasil SFS serta ciri ke-1 dan ke-6 untuk hasil SBS. Ciri-ciri selain kedua pasang ciri di atas berbeda dengan ciri yang dihasilkan oleh skema 2. Hal ini membuktikan bahwa sekalipun secara spektrum terlihat bahwa informasi sinyal EKG yang berada di atas frekuensi 62,5 Hz tidak terlalu signifikan tetapi tetap diperlukan sebagai ciri untuk membedakan data yang satu dengan data yang lain.

Dekomposisi paket wavelet dengan metode 1 lebih baik dalam akurasi. Ciri yang dominan pada skema 1 adalah ciri ke-1, 5, 9, dan 13. Cukup dengan keempat ciri tersebut akurasi sistem bisa ditingkatkan sampai 97,33%.

TABEL VII  
AKURASI RATA-RATA DENGAN CIRI KE-1, 5, 9, DAN 13 HASIL SFS

Jarak	Euclidean			Cityblock		
	K=1	K=3	K=5	K=1	K=3	K=5
Nilai K	K=1	K=3	K=5	K=1	K=3	K=5
Akurasi (%)	93.33	93.33	92	94	93.33	92.67

Jarak	Cosine			Correlation		
	K=1	K=3	K=5	K=1	K=3	K=5
Nilai K	K=1	K=3	K=5	K=1	K=3	K=5
Akurasi (%)	96	97.33	96.77	95.33	95.33	94

TABEL VIII  
AKURASI RATA-RATA DENGAN CIRI KE-1, 4, 13, 18, 21, 22, 28, 29, 30, 31, DAN 32 HASIL SBS

Jarak	Euclidean			Cityblock		
	K=1	K=3	K=5	K=1	K=3	K=5
Nilai K	K=1	K=3	K=5	K=1	K=3	K=5
Akurasi (%)	94.67	95.53	96	94	94.67	96.67

Jarak	Cosine			Correlation		
	K=1	K=3	K=5	K=1	K=3	K=5
Nilai K	K=1	K=3	K=5	K=1	K=3	K=5
Akurasi (%)	80.67	80	81.33	79.33	79.33	80.67

#### IV. KESIMPULAN

Pada penelitian ini telah dibandingkan 2 skema dekomposisi paket wavelet untuk pengenalan sinyal EKG. Dari pengujian akurasi, skema 1 menghasilkan akurasi yang lebih baik dibandingkan dengan skema 2. Dengan menggunakan teknik pemilihan ciri SFS didapatkan 4 ciri yang dominan dari 32 ciri hasil dekomposisi paket wavelet orde 5 dengan *mother wavelet* Daubechies1. Keempat ciri menghasilkan akurasi rata-rata 97.33 %, lebih tinggi penggunaan 32 ciri sekaligus pada skema 1.

#### REFERENSI

- [1] W. J. Tompkins, "Electrocardiography," in *Biomedical Digital Signal Processing*, W. J. Tompkins, Ed. New Jersey: Prentice Hall, 2000, pp. 24–54.
- [2] J. L. Schuster, C. Spence, M. Jacobs, and A. Wilkonson, "Living with Advanced Congestive Heart Failure : A Guide for Family Caregivers," 2002.
- [3] S. M. Al-khatib, N. A. Lapointe, and R. Chatterjee, "Treatment of Atrial," *Comp. Eff. Rev.*, no. 119, 2013.
- [4] B. S. Kim, S. K. Yoo, and M. H. Lee, "Wavelet-Based Low-Delay ECG Compression Algorithm for Continuous ECG Transmission," *Ieee Trans. Inf. Technol. Biomed.*, vol. 10, no. 1, pp. 77–83, 2006.
- [5] E. Alexandre, A. Pena, and M. Sobreira, "On the Use of 2-D Coding Techniques for ECG Signals," *Ieee Trans. Inf. Technol. Biomed.*, vol. 10, no. 4, pp. 809–811, 2006.
- [6] V. B. Romero, "ECG baseline wander removal and noise suppression analysis in an embedded platform," Universidad Complutense de Madrid, 2009.
- [7] S. Z. Mahmoodabadi, A. Ahmadian, and M. D. Abolhasani, "ECG Feature Extraction Using Daubechies Wavelets," in *Proc. of the fifth IASTED International Conference Visualization, Imaging, and Image Processing*, 2005, vol. 2, no. 2, pp. 343–348.

- [8] C. Saritha, V. Sukanya, and Y. N. Murthy, "ECG Signal Analysis Using Wavelet Transforms," *Bulg. J. Phys.*, vol. 35, pp. 68–77, 2008.
- [9] A. Rizal and V. Suryani, "Pengenalan signal ekg menggunakan dekomposisi paket wavelet dan k-means-clustering," in *Proceeding Seminar Nasional Aplikasi Teknologi Inofrmasi 2008(SNATI 2008)*, 2008, vol. 2008, no. Snati, pp. 5–8.
- [10] L. Brechet, M. Lucas, C. Doncarli, and D. Farina, "Compression of Biomedical Signals with Mother Wavelet Optimization and Best-Basis Wavelet Packet Selection," *IEEE Trans. Biomed. Eng.*, vol. 54, no. 12, pp. 2186 – 2192, 2007.
- [11] A. Surtono, T. S. Widodo, and M. Tjokronagoro, "Analisis Klasifikasi Sinyal EKG Berbasis Wavelet dan Jaringan Syaraf Tiruan," *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 1, no. 3, pp. 60–66, 2012.
- [12] A. Rizal, T. L. R. Mengko, and A. B. Suksmono, "Lung Sound Recognition Using Wavelet Packet Decomposition and ART2 ( Adaptive Resonance Theory 2 ) Neural Network," in *Proceeding Biomedical Engineering Day 2006*, 2006, vol. 2, pp. 2–6.
- [13] A. Rizal, "Wrapper Features Subset Selection Pada Ekstraksi Ciri Sinyal EKG Menggunakan Metode Dekomposisi Paket Wavelet," *J. Inform.*, vol. 8, no. 2, pp. 105–114, 2012.
- [14] Physionet.org, "ECG Database." [Online]. Available: <http://physionet.org/physiobank/database/#ecg>.
- [15] E. A. Ashley and J. Niebauer, "Conquering the ECG - Cardiology Explained - NCBI Bookshelf," in *Cardiology Explained*, London: Remedica, 2004.
- [16] M. Kociolek, A. Materka, M. Strzelecki, and P. Szezykowski, "Discrete Wavelet Transform – Derived Features for Digital Image Texture Analysis," in *Proceeding of International Conference and Electronics System*, 2001, no. September, pp. 163–168.
- [17] R. Palaniappan, *Biological Signal Analysis*. Ventus Publishing ApS, 2010, p. 117.
- [18] S. Reichert, R. Gass, C. Brandt, and E. Andrès, "Analysis of Respiratory Sounds : State of the Art," *Clin. Med. Circ. Respir. Pulm. Med.*, vol. 2, pp. 45–58, 2008.
- [19] A. Goshtasby, *Image Registration, Priciples, Tools and Methods*, First. Springer-Verlag London Limited, 2012.