

EKSTRASI FITUR SINYAL EKG MYOCARDIAL INFARCTION MENGGUNAKAN DISCRETE WAVELET TRANSFORMATION

(FEATURES EXTRACTION ON MYOCARDIAL INFARCTION ECG SIGNAL USING DISCRETE WAVELET TRANSFORMATION)

Siti Agrippina Alodia Yusuf¹⁾, Nani Sulistianingsih²⁾, dan Helmi Imaduddin³⁾

^{1,2)}Program Studi Sistem dan Informasi, Fakultas Teknik

Universitas Muhammadiyah Mataram

³⁾Program Studi Teknik Informatika, Fakultas Komunikasi dan Informatika

Universitas Muhammadiyah Surakarta

e-mail: siti.agrippina@ummat.ac.id¹⁾, nani.sulistianingsih@ummat.ac.id²⁾, h1776@ums.ac.id³⁾

ABSTRAK

Salah satu tahapan penting pada proses identifikasi sinyal EKG adalah ekstraksi fitur, dimana fitur yang diperoleh mencirikan kondisi dari jantung. Kondisi dari jantung dapat dilihat berdasarkan gelombang-gelombang yang dihasilkan pada sinyal EKG, dimana gelombang-gelombang tersebut dihasilkan oleh aktivitas listrik jantung. Pada penelitian ini, dua tipe mother wavelet akan dibandingkan untuk melihat tipe mana yang paling cocok untuk mengekstraksi fitur dari sinyal EKG. Tipe mother wavelet yang akan dibandingkan adalah Daubechies dan Symlet dengan orde masing-masing adalah 5, 6, dan 7 untuk Daubechies, dan 6, 7, dan 8 untuk Symlet. Sinyal EKG dengan kondisi jantung MI dan normal yang telah ditingkatkan kualitasnya dan telah melalui proses pemotongan sinyal, diekstraksi menggunakan Discrete Wavelet Transformation (DWT) dengan mother wavelet Daubechies dan Symlet pada dekomposisi level dua dan fitur yang diambil yaitu fitur statistik seperti rata-rata, median, standar deviasi, kurtosis, dan skewness. Fitur-fitur diambil dari sub-band D2 dan D1, sehingga total fitur yang diperoleh yaitu 10 fitur. Sinyal EKG kemudian diklasifikasi menggunakan metode KNN dan untuk mendapatkan hasil yang tergeneralisasi, maka K-fold cross validation juga diaplikasikan. Berdasarkan percobaan yang telah dilakukan, diperoleh akurasi tertinggi sebesar 94% dengan sensitivitas dan spesifisitas sebesar 82% dan 91% dengan mengaplikasikan mother wavelet Daubechies orde 7.

Kata Kunci: DWT, ECG, KNN, K-Fold,

ABSTRACT

One important step in the process of identifying EKG signals is feature extraction, where the obtained features characterize the condition of the heart. The condition of the heart can be observed based on the waves produced in the EKG signal, which are generated by the electrical activity of the heart. In this study, two types of mother wavelets will be compared to determine which type is most suitable for extracting features from EKG signals. The types of mother wavelets to be compared are Daubechies and Symlet with orders of 5, 6, and 7 for Daubechies, and 6, 7, and 8 for Symlet. EKG signals with MI and normal heart conditions that have been improved in quality and have undergone signal segmentation are extracted using Discrete Wavelet Transformation (DWT) with Daubechies and Symlet mother wavelets at the two-level decomposition, and statistical features such as mean, median, standard deviation, kurtosis, and skewness are taken. Features are extracted from the D2 and D1 sub-bands, resulting in a total of 10 features obtained. The EKG signals are then classified using the KNN method, and to obtain generalized results, K-fold cross-validation is also applied. Based on the experiments conducted, the highest accuracy obtained was 94% with sensitivity and specificity of 82% and 91% by applying the Daubechies mother wavelet of order 7.

Keywords: DWT, ECG, KNN, K-Fold.

I. PENDAHULUAN

Penyakit kardiovaskular merupakan penyakit yang menjadi penyebab utama kematian di seluruh dunia pada 20 tahun terakhir.

Penyakit kardiovaskular merupakan istilah umum yang digunakan untuk menggambarkan kondisi dari jantung dan pembuluh darah. Terdapat beberapa tipe dari penyakit kardiovaskular, seperti penyakit jantung koroner, serangan jantung, gagal

jantung, penyakit jantung bawaan dan struk. Pada tahun 2019, menurut *World Health Organization* (WHO), diperkirakan sekitar 17.9 juta orang meninggal dari penyakit kardiovaskular, angka kematian ini menggambarkan 32% dari total kematian di seluruh dunia dan dari total kematian tersebut 85%-nya diakibatkan oleh serangan jantung dan struk [1]. Sementara itu, di Indonesia sendiri dari total 1.8 juta kematian pada tahun 2016, 35% dari total kematian tersebut disebabkan oleh penyakit kardiovaskular [2]. Serangan jantung yang disebut juga dengan *Myocardial Infarction* (MI) digambarkan sebagai nekrosis miokardium yang disebabkan oleh ketidakmampuan jantung untuk mendapatkan oksigen melalui arteri koronernya, lebih lanjut lagi, di Amerika Serikat, sekitar satu juta orang setiap tahun menderita serangan jantung [3]. Oleh sebab itu, deteksi dini penyakit kardiovaskular, khususnya serangan jantung sangat krusial untuk dilakukan agar mengurangi angka kematian yang disebabkan oleh penyakit tersebut.

Elektrokardiogram (EKG) merupakan alat yang digunakan untuk mendeteksi penyakit kardiovaskular, alat ini bersifat non-invasif dan bekerja dengan cara merekam aktivitas elektrik jantung dengan cara menempelkan elektroda pada permukaan dada, lengan, atau kaki. Hasil dari EKG adalah gelombang-gelombang yang merupakan gambaran dari kondisi jantung, oleh sebab itu, setiap gelombang memiliki karakteristik tersendiri yang didasarkan pada kondisi jantung. Gelombang pada EKG terdiri dari lima macam gelombang, yaitu gelombang P, Q, R, S, dan T. setiap gelombang merepresentasikan aktivitas elektrik dari masing-masing ruang pada jantung [4]. Gelombang P menggambarkan kondisi depolarisasi dari atrium, gelombang Q, R, dan S membentuk kompleks QRS dan menggambarkan depolarisasi dari ventrikel, sedangkan gelombang T menggambarkan repolarisasi dari ventrikel [5].

Untuk menganalisis sinyal EKG secara manual dibutuhkan pengalaman yang banyak, selain itu terkadang sangat sulit untuk mengidentifikasi perubahan kecil pada gelombang EKG yang disebabkan oleh amplitude gelombang yang kecil. Di sisi lain, menganalisis sinyal EKG secara otomatis masih merupakan tantangan berat yang disebabkan oleh beberapa hal pada proses identifikasinya, salah satunya tantangan pada proses identifikasi sinyal EKG adalah tidak adanya standarisasi dari karakteristik sinyal EKG, variabilitas pada gelombang, dan individualitas pada pola sinyal EKG [6]. Oleh sebab itu,

menemukan fitur yang paling cocok untuk merepresentasikan sinyal EKG agar memudahkan identifikasi masih menjadi tantangan. Pada penelitian ini, akan dilakukan identifikasi sinyal EKG dengan kondisi jantung MI dengan mengambil fitur statistik seperti rata-rata, median, standar deviasi, skewness, dan kurtosis yang diekstrak menggunakan DWT. Fitur-fitur tersebut kemudian akan diumpungkan ke KNN untuk kemudian dilakukan klasifikasi.

II. STUDI PUSTAKA

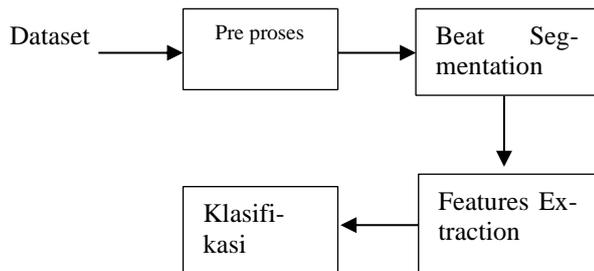
Beberapa penelitian untuk klasifikasi pada sinyal EKG telah dilakukan dengan memanfaatkan berbagai macam metode ekstraksi fitur. Pada [7], klasifikasi sinyal EKG pada penyakit aritmia dilakukan dengan menggunakan fitur rata-rata akustik yang didapatkan dari ekstraksi *Mel Frequency Cepstral Coefficient* (MFCC). Penelitian lain dengan menggunakan sinyal EKG aritmia yang sama juga dilakukan oleh [8], penelitian tersebut mengekstraksi fitur statistik pada sinyal EKG menggunakan *Discrete Wavelet Transformation* (DWT) dengan *mother wavelet Daubechies*. Fitur-fitur statistik yang diekstrak antara lain power spektrum, rata-rata absolut, standar deviasi, skewness, kurtosis, rasio rata-rata, puncak positif, puncak negative, dan puncak negative ke dua pada lima sub-band yang diperoleh dari dekomposisi level lima. Kedua penelitian tersebut memperoleh akurasi di atas 95%.

Penelitian lain membandingkan metode ekstraksi fitur, yakni antara MFCC dengan DWT [9] pada sinyal EKG penyakit MI. Penelitian tersebut membandingkan MFCC, DWT dengan *mother wavelet Haar* dan *Symlet 7*. Hasil yang diperoleh menunjukkan bahwa ekstraksi fitur menggunakan MFCC memberikan akurasi yang lebih tinggi, yaitu sebesar 84%. MFCC dan DWT dikombinasikan pada penelitian [10], sinyal EKG kondisi jantung MI yang sudah didekomposisi menggunakan DWT diekstrak cirinya menggunakan MFCC. Akurasi yang diperoleh sebesar 88%. Toulmi [11] mengekstraksi enam ciri statistik pada sinyal EKG aritmia, ciri tersebut adalah rata-rata, rata-rata akar kuadrat, variasi, standar deviasi, kurtosis dan entropi wavelet. Dengan menggunakan *mother wavelet Coiflet 5* dan klasifikasi *Support Vector Machine* (SVM) diperoleh akurasi sebesar 87.5%. Masih menggunakan sinyal EKG aritmia, penelitian yang dilakukan oleh [12] melakukan ekstraksi fitur statistik menggunakan DWT dan

klasifikasi KNN, hasil akurasi yang diperoleh sebesar 91% dengan sensitivitas 100% dan spesifisitas sebesar 83%.

III. METODE PENELITIAN

Penelitian ini terdiri dari lima tahapan, yaitu tahapan pengumpulan dataset, pre proses, *beat segmentation*, ekstraksi fitur, dan klasifikasi seperti yang ditunjukkan pada Gambar 1.



Gambar 1. Proses penelitian

A. Dataset

Dataset yang digunakan pada penelitian ini adalah *The Physikalisch Technische Bundesanstalt Diagnostic ECG Database (PTB-DB)* yang tersedia di Physionet. Dataset ini disediakan oleh Divisi Kardiologi Universitas Benjamin Franklin Jerman. Setiap sinyal EKG terdiri dari 15 macam *lead*, yaitu *lead* i, ii, iii, avr, avl, avf, v1, v2, v3, v4, v5, v6, vx, vy, dan vz. Dari keseluruhan *lead*, hanya *lead* ii yang akan digunakan. Dari total 200 data yang diperoleh, 52 data merupakan kondisi jantung sehat, dan 148 data merupakan kondisi jantung MI. Masing-masing sinyal EKG berdurasi 10 detik dengan frekuensi sampling sebesar 1.000Hz, dengan demikian masing-masing sinyal EKG memiliki Panjang data sebesar 10.000.

B. Pre proses

Tahap pre proses ini bertujuan untuk meningkatkan kualitas sinyal dengan menghilangkan derau yang ada. Terdapat dua tipe derau pada sinyal EKG yang umum muncul ketika proses perekaman sinyal, yaitu derau pada frekuensi rendah dan frekuensi tinggi. Salah satu derau yang muncul pada frekuensi rendah adalah *baseline wander*, dimana jenis derau ini muncul akibat pergerakan badan dan pergerakan sistem pernafasan ketika proses perekaman sinyal berlangsung. Sedangkan, derau pada frekuensi tinggi seperti *power line interference* atau gangguan listrik muncul diakibatkan oleh

gangguan pada saluran listrik atau *power line interference* [13].

Derau *baseline wander* menyebabkan sinyal EKG bergeser dari garis isoline atau garis nol seperti yang ditunjukkan pada Gambar 2, sehingga akan menyebabkan kesulitan ketika akan mendekati puncak dari sinyal, yaitu gelombang R, sedangkan deteksi puncak dari sinyal dibutuhkan ketika akan melakukan segmentasi sinyal. Untuk mengatasi permasalahan dari *baseline wander*, maka filter median seperti pada persamaan (1) digunakan untuk menghilangkan derau tersebut. Median filter merupakan salah satu metode filtering sinyal yang digunakan untuk mengurangi derau namun tetap mempertahankan karakteristik penting dari sinyal [14].

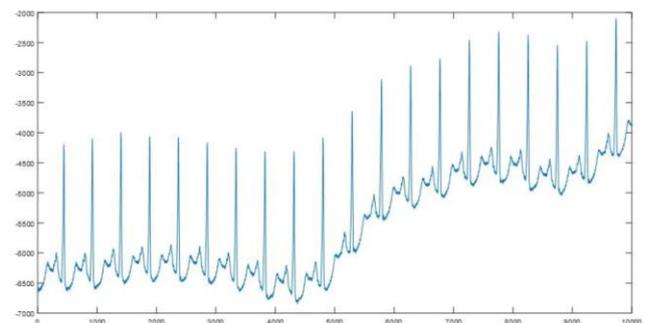
$$y(n) = \text{median}[x(n - k), \dots, x(n), \dots, x(n + k)] \quad (1)$$

Dimana:

$y(n)$ adalah sinyal hasil filter median

$x(n)$ adalah sinyal masukan

$x-n$ dan $x+k$ adalah sampel yang diurutkan mulai dari nilai terkecil hingga terbesar



Gambar 2. Derau baseline wander pada sinyal EKG kondisi jantung MI

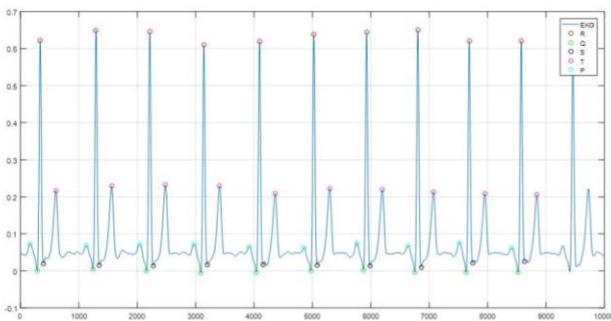
C. Beat Segmentation

Tahap *beat segmentation* merupakan tahap pemotongan sinyal berdasarkan pada siklus dari jantung, dimana satu siklus jantung terdiri dari gelombang P, T, dan kompleks QRS. Gelombang R merupakan gelombang dengan amplitude tertinggi dan merupakan puncak yang paling terlihat, oleh sebab itu gelombang R dijadikan patokan untuk melakukan segmentasi. Segmentasi dilakukan dengan cara mendeteksi puncak dari gelombang R, kemudian berdasarkan posisi puncak dilakukan pemotongan sebesar 200 data ke kanan dan 450

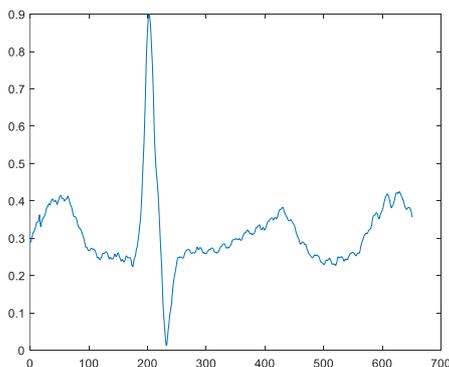
data ke kiri, sehingga diperoleh Panjang sinyal per segmen sebesar 651 data.

Salah satu metode yang umum digunakan untuk mendeteksi puncak R pada sinyal EKG adalah metode *teager Energy Operation* (TEO). Metode ini juga banyak digunakan pada sinyal suara dan gambar karena kemampuannya untuk mendeteksi sinyal yang terkonsentrasi dalam interval waktu yang singkat dan pada pita frekuensi tinggi [15]. Hanya saja, metode TEO memiliki kelemahan, yaitu tingkat sensitivitasnya akan berkurang ketika harus mendeteksi sinyal yang memiliki tingkat derau yang tinggi. Pada penelitian [16], metode TEO dikembangkan menjadi *multiresolution TEO* (MTEO), dimana metode ini terdiri dari k-TEO pada setiap kanalnya, dan pada setiap sampel pada domain waktu, kanal keluaran akan dibandingkan untuk memperoleh nilai maksimum. Hasil deteksi puncak-puncak gelombang menggunakan MTEO ditunjukkan oleh Gambar 3.

Gelombang dengan puncak R yang sudah terdeteksi kemudian disegmentasi sepanjang 651 data, dimana 200 data ke kiri dan 450 data ke kanan dari puncak R. Dengan panjang data 651, satu siklus jantung dengan gelombang P, QRS, dan T sudah terpenuhi. Sinyal hasil segmentasi ditunjukkan oleh Gambar 4.



Gambar 3. Hasil deteksi puncak menggunakan MTEO

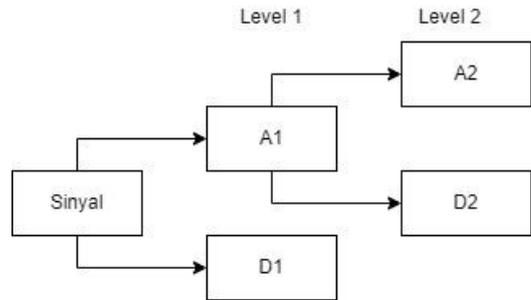


Gambar 4. Hasil segmentasi sinyal per siklus jantung

D. Ekstraksi Fitur

Ekstraksi fitur merupakan tahap pengambilan ciri sinyal yang kemudian digunakan sebagai pembeda antara satu sinyal dengan sinyal yang lain. Pada tahap ini, sinyal EKG yang telah melewati proses segmentasi akan didekomposisi menggunakan DWT dengan dua tipe *mother wavelet*, yaitu Daubechies dan Symlet untuk dianalisis dan diambil ciri statistiknya. DWT merupakan sebuah fungsi matematika yang memotong data menjadi beberapa komponen frekuensi yang berbeda. DWT memiliki kelebihan dibandingkan metode transformasi Fourier tradisional untuk merepresentasikan fungsi-fungsi yang memiliki diskontinuitas dan puncak-puncak tajam serta berbagai pilihan fungsi dasar, selain itu DWT juga merupakan metode yang efisien untuk menganalisis sinyal *non-stationary* [17].

Pada DWT, sinyal difilter menjadi dua bagian yaitu *low pass filter* (LPF) dan *high pass filter* (HPF). Hasil keluaran dari LPF disebut sebagai aproksimasi, sedangkan keluaran dari HPF disebut sebagai detail koefisien. Sinyal hasil dari aproksimasi kemudian pada level dekomposisi selanjutnya dapat diturunkan kembali menjadi LPF dan HPF, dengan begitu sinyal memiliki banyak komponen pada level yang berbeda [9]. Gambar 5 menunjukkan struktur dekomposisi dari DWT.



Gambar 5. DWT 2 level dekomposisi

Implementasi dari LPF dan HPF ditunjukkan oleh persamaan berikut.

$$A[n] = \sum_{k=-\infty}^{\infty} s[k]g[2n - k] \tag{2}$$

$$D[n] = \sum_{k=-\infty}^{\infty} s[k]h[2n - k] \tag{3}$$

Memilih tipe *mother wavelet* yang sesuai dengan sinyal merupakan bagian penting pada proses ini, oleh sebab itu dua tipe *mother wavelet* akan digunakan untuk menentukan tipe wavelet terbaik untuk mengambil ciri dari sinyal EKG. Tipe

pertama yaitu Daubechies, dengan menggunakan Daubechies orde 5, 6 dan 7. Tipe *mother* wavelet yang ke dua adalah Symlet, dengan orde 6, 7, dan 8.

Pada penelitian ini, sinyal EKG yang telah disegmentasi akan didekomposisi pada level 2, sehingga akan menghasilkan 3 sub-band, yaitu A2, D2, dan D1. Ciri statistik seperti rata-rata, median, standar deviasi, skewness, dan kurtosis akan diekstrak pada dua sub-band detail (D2 dan D1), sehingga pada satu sinyal EKG akan diperoleh sebanyak 10 ciri.

E. Klasifikasi

Salah satu metode yang umum digunakan untuk melakukan klasifikasi adalah metode *K-Nearest Neighbour* (KNN). KNN bekerja dengan cara mengklasifikasikan objek berdasarkan jarak terdekatnya. Ada dua tahapan pada klasifikasi KNN, pertama yaitu tahap pelatihan dan kedua yaitu tahap klasifikasi. Pada tahap pelatihan, KNN menyimpan vektor fitur dan label kelas dari contoh pelatihan. Setiap contoh pelatihan direpresentasikan sebagai vector dalam ruang ciri multidimensi, dimana setiap dimensi merepresentasikan suatu fitur dari objek. Setelah tahap pelatihan selesai, KNN dapat melakukan klasifikasi pada titik uji dengan cara menjadi K contoh pelatihan terdekat dari titik uji dalam ruang ciri. K kemudian digunakan untuk menentukan label kelas titik uji, di mana label kelas tersebut merupakan label yang paling sering muncul di antara K contoh pelatihan terdekat [18]. Untuk mengukur jarak antara K dengan pelatihan, maka digunakan pengukuran Euclidean dengan persamaan:

$$d_{st} = \sqrt{\sum_{j=1}^n (x_{sj} - y_{tj})^2} \quad (4)$$

Dimana x dan y adalah dua data yang jaraknya harus ditemukan, sedangkan n adalah jumlah setiap dimensi data.

F. K-Fold Cross Validation

K-fold cross validation juga diterapkan pada penelitian ini agar variasi hasil pengenalan rendah. Teknik ini memungkinkan data dibagi menjadi sejumlah K dari dataset. Dataset ke-1 digunakan sebagai data pengujian sedangkan dataset ke-2, ke-3...K digunakan sebagai data pelatihan. Kemudian,

proses diulang dimana dataset ke-2 digunakan sebagai data pengujian, sedangkan dataset ke-1, ke-3...K digunakan sebagai data pelatihan. Proses ini berulang sampai K kali. Total akurasi kemudian dibagi dengan K. Pada penelitian ini, nilai K yang akan diujikan adalah 3 dan 6.

IV. HASIL DAN PEMBAHASAN

Pada penelitian ini, sinyal EKG dengan kondisi jantung MI dan normal diklasifikasi menggunakan KNN berdasarkan fitur statistik yang telah diekstrak. Sebanyak 200 sinyal EKG yang diperoleh, 52 data diberikan label sebagai sinyal EKG normal dan 148 data ditandai sebagai sinyal EKG MI. Sinyal-sinyal tersebut kemudian ditingkatkan kualitasnya menggunakan filter median, dimana filter ini dapat menghilangkan derau yang ada pada sinyal EKG, seperti derau *baseline wander*. Setelah posisi gelombang sinyal tepat berada pada garis isoline, puncak R dari setiap sinyal kemudian dideteksi. Hal ini bertujuan agar sinyal dapat dipotong atau disegmentasi sesuai dengan satu siklus dari jantung, dimana dalam satu siklus jantung terdapat gelombang P, QRS, dan T. Dari hasil segmentasi, diperoleh sebanyak 678 sinyal EKG yang siap untuk diekstrak fiturnya. Sinyal yang telah disegmentasi kemudian didekomposisi pada level 2 menggunakan dua tipe *mother* wavelet, yaitu Daubechies dan Symlet. Pada Daubechies, digunakan orde 5, 6, dan 7, sedangkan pada Symlet digunakan orde 6, 7, dan 8. Pemilihan orde untuk ekstraksi fitur didasarkan pada kemiripan bentuk gelombang *mother* wavelet dengan sinyal EKG yang dianalisis. Hasil dekomposisi yaitu berupa 3 sub-band, A2, D2, dan D1. Fitur statistik berupa rata-rata, median, standar deviasi, skewness, dan kurtosis diekstrak pada sub-band D2 dan D1, sehingga pada masing-masing sinyal EKG diperoleh sebanyak 10 ciri.

Fitur hasil ekstraksi kemudian akan diumpankan ke KNN untuk diklasifikasi. Pada penelitian ini, tiga nilai ketetangaan K akan diujikan, yaitu K=3, K=5 dan K=7, hal ini bertujuan untuk mengetahui pengaruh nilai ketetangaan pada KNN. Angka ganjil dipilih untuk menghilangkan kemungkinan adanya hasil yang seri pada klasifikasi nanti. Untuk mendapatkan hasil klasifikasi yang tergeneralisir, maka diterapkan pula *K-fold cross validation*, dengan nilai K pada *K-fold* adalah 3 dan 6.

Hasil klasifikasi dari masing-masing orde *mother* wavelet ditunjukkan pada tabel-tabel berikut.

Tabel 1. Hasil klasifikasi Daubechies orde 5

KNN	3-Fold			6-Fold		
	Ak	Sen	Spe	Ak	Sen	Spe
3	77%	75%	80%	81%	81%	82%
5	77%	77%	78%	81%	80%	82%
7	80%	79%	80%	82%	85%	80%

Tabel 2. Hasil Klasifikasi Daubechies orde 6

KNN	3-Fold			6-Fold		
	Ak	Sen	Spe	Ak	Sen	Spe
3	79%	82%	76%	80%	81%	78%
5	78%	78%	79%	81%	85%	78%
7	75%	77%	73%	81%	84%	78%

Tabel 3. Hasil Klasifikasi Daubechies orde 7

KNN	3-Fold			6-Fold		
	Ak	Sen	Spe	Ak	Sen	Spe
3	91%	81%	79%	91%	83%	80%
5	91%	80%	85%	94%	82%	91%
7	90%	90%	80%	92%	83%	88%

Tabel 4. Hasil Klasifikasi Symlet orde 6

KNN	3-Fold			6-Fold		
	Ak	Sen	Spe	Ak	Sen	Spe
3	75%	76%	74%	77%	80%	74%
5	78%	77%	80%	81%	79%	82%
7	78%	81%	75%	81%	79%	82%

Tabel 5. Hasil Klasifikasi Symlet orde 7

KNN	3-Fold			6-Fold		
	Ak	Sen	Spe	Ak	Sen	Spe
3	74%	72%	76%	79%	81%	76%
5	76%	71%	80%	81%	85%	79%
7	76%	76%	76%	79%	77%	81%

Tabel 6. Hasil Klasifikasi Symlet orde 8

KNN	3-Fold			6-Fold		
	Ak	Sen	Spe	Ak	Sen	Spe
3	78%	74%	82%	81%	82%	81%
5	81%	80%	81%	83%	88%	78%
7	81%	79%	82%	83%	92%	74%

Dari keseluruhan tabel, terlihat bahwa akurasi tertinggi dari masing-masing orde *mother* wavelet diperoleh pada saat menggunakan *6-fold* cross validation. Pada Daubechies orde 5 dan orde 6, rata-rata akurasi yang diperoleh yaitu sebesar 77%, sedangkan rata-rata akurasi meningkat menjadi 90% pada orde 7. Pada tipe *mother* wavelet Symlet pada seluruh orde yang digunakan, rata-rata akurasi yang diperoleh adalah 77%.

Akurasi tertinggi diperoleh sebesar 94%, dengan sensitivitas dan spesifisitas sebesar 82%

dan 91% berturut-turut dengan menggunakan Daubechies orde 7 pada nilai ketetanggaan 5 dan 6-fold. Akurasi yang diperoleh pada penelitian ini lebih baik jika dibandingkan dengan penelitian yang dilakukan oleh [9], [10]. Tabel 7 menunjukkan hasil perbandingan dengan penelitian sebelumnya.

Tabel 7. Perbandingan dengan Penelitian Sebelumnya

Penelitian Sebelumnya	Metode	Akurasi
Siti [9]	DWT Symlet 7 Level 6	71 %
Siti [10]	DWT Symlet 7 Level 6 + MFCC	88%
Penelitian ini	DWT Daubechies 7 Level 2	94%

V. KESIMPULAN

Pada penelitian ini, telah dilakukan ekstraksi fitur pada sinyal EKG dengan kondisi jantung MI dan normal menggunakan metode DWT sebagai ekstraktor. Untuk memperoleh hasil akurasi terbaik, maka dua tipe *mother* wavelet diujikan, yaitu Daubechies dan Symlet. Pada tipe Daubechies digunakan orde 5, 6, dan 7. Sedangkan pada Symlet digunakan orde 6, 7, dan 8. Fitur statistik dari sinyal EKG kemudian diekstrak setelah sinyal didekomposisi pada level 2 pada sub-band D2 dan D1. Fitur-fitur statistik tersebut kemudian diinputkan pada klasifier KNN, dengan nilai ketetanggaan K yang diujikan adalah 3, 5, dan 7. Selain itu, *K-fold cross validation* juga diaplikasikan pada saat klasifikasi dengan nilai K yaitu 3 dan 6. Berdasarkan percobaan yang dilakukan, nilai fold mempengaruhi hasil akurasi, dimana dengan nilai fold K = 6 memberikan hasil akurasi yang lebih tinggi pada semua tipe *mother* wavelet. Selain itu, nilai ketetanggaan pada KNN juga berpengaruh pada nilai akurasi yang diperoleh, dimana rata-rata akurasi tinggi diperoleh menggunakan nilai ketetanggaan K = 5. Berdasarkan hal-hal tersebut, hasil yang diperoleh yaitu akurasi sebesar 94% dengan sensitivitas dan spesifisitas sebesar 82% dan 91% dengan menggunakan tipe *mother* wavelet pada orde 7.

Pada penelitian selanjutnya, dapat dilakukan ekstraksi fitur pada sub-band lain, yaitu sub-band aproksimasi untuk dibandingkan dengan sub-band detail. Selain itu, fitur morfologi pada sinyal yang telah disegmentasi juga dapat diekstrak untuk dijadikan fitur sinyal.

DAFTAR PUSTAKA

- [1] “Cardiovascular diseases (CVDs).pdf.”
- [2] World Health Organization, *Noncommunicable diseases country profiles 2018*. Geneva: World Health Organization, 2018. Accessed: Nov. 08, 2022. [Online]. Available: <https://apps.who.int/iris/handle/10665/274512>
- [3] N. A. Khadse, A. M. Wankhade, and A. G. Gaiki, “Myocardial Infarction: Etiology, Risk Factors, Pathophysiology, Diagnosis and Management,” *Am. J. PharmTech Res.*, vol. 10, no. 1, pp. 173–190, Feb. 2020, doi: 10.46624/ajptr.2020.v10.i1.014.
- [4] M. S. Al-Ani, “ECG Waveform Classification Based on P-QRS-T Wave Recognition,” *UHD J. Sci. Technol.*, vol. 2, no. 2, pp. 7–14, Jul. 2018, doi: 10.21928/uhdjst.v2n2y2018.pp7-14.
- [5] P. Madona, R. I. Basti, and M. M. Zain, “PQRST wave detection on ECG signals,” *Gac. Sanit.*, vol. 35, pp. S364–S369, 2021, doi: 10.1016/j.gaceta.2021.10.052.
- [6] S. H. Jambukia, V. K. Dabhi, and H. B. Prajapati, “Classification of ECG signals using machine learning techniques: A survey,” in *2015 International Conference on Advances in Computer Engineering and Applications*, Ghaziabad, India: IEEE, Mar. 2015, pp. 714–721. doi: 10.1109/ICACEA.2015.7164783.
- [7] Y. Arpitha, G. L. Madhumathi, and N. Balaji, “Spectrogram analysis of ECG signal and classification efficiency using MFCC feature extraction technique,” *J. Ambient Intell. Humaniz. Comput.*, vol. 13, no. 2, pp. 757–767, Feb. 2022, doi: 10.1007/s12652-021-02926-2.
- [8] S. Mian Qaisar and S. Fawad Hussain, “Arrhythmia Diagnosis by Using Level-Crossing ECG Sampling and Sub-Bands Features Extraction for Mobile Healthcare,” *Sensors*, vol. 20, no. 8, p. 2252, Apr. 2020, doi: 10.3390/s20082252.
- [9] S. A. Alodia Yusuf and R. Hidayat, “MFCC Feature Extraction and KNN Classification in ECG Signals,” in *2019 6th International Conference on Information Technology, Computer and Electrical Engineering (ICITACEE)*, Semarang, Indonesia: IEEE, Sep. 2019, pp. 1–5. doi: 10.1109/ICITACEE.2019.8904285.
- [10] S. A. A. Yusuf and R. Hidayat, “Feature Extraction of ECG Signals using Discrete Wavelet Transform and MFCC,” in *2019 5th International Conference on Science in Information Technology (ICSITech)*, Yogyakarta, Indonesia: IEEE, Oct. 2019, pp. 167–170. doi: 10.1109/ICSITech46713.2019.8987544.
- [11] Y. Toulmi, N. Benayad, and B. D. Taoufiq, “Electrocardiogram signals classification using discrete wavelet transform and support vector machine classifier,” *IAES Int. J. Artif. Intell. IJ-AI*, vol. 10, no. 4, p. 960, Dec. 2021, doi: 10.11591/ijai.v10.i4.pp960-970.
- [12] Y. Toulmi, T. Belhoussine Drissi, and B. Nsiri, “ECG signal diagnosis using Discrete Wavelet Transform and K-Nearest Neighbor classifier,” in *The 4th International Conference on Networking, Information Systems and Security*, KENITRA AA Morocco: ACM, Apr. 2021, pp. 1–6. doi: 10.1145/3454127.3457628.
- [13] A. Velayudhan and S. Peter, “Noise Analysis and Different Denoising Techniques of ECG Signal - A Survey,” *IOSR J. Electron. Commun. Eng.*, p. 5, 2016.
- [14] I. Fahruzi, “Mengurangi Pengaruh Noise Baseline Wander pada Sinyal Electrocardiogram (ECG),” vol. 5, no. 1, p. 5, Mar. 2013.
- [15] J. H. Choi, H. K. Jung, and T. Kim, “A New Action Potential Detector Using the MTEO and Its Effects on Spike Sorting Systems at Low Signal-to-Noise Ratios,” *IEEE Trans. Biomed. Eng.*, vol. 53, no. 4, pp. 738–746, Apr. 2006, doi: 10.1109/TBME.2006.870239.
- [16] J. H. Choi and T. Kim, “Neural action potential detector using multi-resolution TEO,” *Electron. Lett.*, vol. 38, no. 12, p. 541, 2002, doi: 10.1049/el:20020386.
- [17] A. Almumri, E. Balakrishnan, and Narasimman, Sundararajan, “Discrete Wavelet Transform Based Feature Extraction in Electrocardiogram Signals,” vol. 17, no. 1, pp. 63–67, 2021.
- [18] I. Saini, D. Singh, and A. Khosla, “QRS detection using K-Nearest Neighbor algorithm (KNN) and evaluation on standard ECG databases,” *J. Adv. Res.*, vol. 4, no. 4, pp. 331–344, Jul. 2013, doi: 10.1016/j.jare.2012.05.007.