

Statistical Feature Extraction Based on Wavelet Transform for Arrhythmia Detection

Indra Abdam Muwakhid^{1*}, Agung Satrio Nugroho²

¹Program Studi Informatika Medis, Universitas Widya Husada Semarang
Jl. Subali Raya No. 12 Krpyak Semarang, 024-7612988, e-mail: abdam.stiess@gmail.com

²Program Studi Teknologi Elektro Medis, Universitas Widya Husada Semarang
Jl. Subali Raya No. 12 Krpyak Semarang, 024-7612988, e-mail:
agungsatrionugroho1905@gmail.com

ARTICLE INFO

History of the article :

Received 30 June 2025

Received in revised form 11 July 2025

Accepted 13 July 2025

Available online 30 July 2025

Keywords:

Arrhythmia, ECG, Wavelet, Statistical Features, Classification

* Correspondence:

Telepon:
+62 85641011699

E-mail:
abdam.stiess@gmail.com

ABSTRACT

Early detection of arrhythmia through electrocardiogram (ECG) signals is crucial for preventing severe cardiac conditions. This study proposes a binary classification approach using statistical features derived from wavelet-transformed ECG signals. The MIT-BIH Arrhythmia Database was used, with signals filtered using a 0.5–50 Hz Butterworth bandpass filter. Signals were segmented into 360-sample windows with 100-sample overlap and labeled based on the majority annotation within each window. Wavelet transformation using Symlet 8 at level 4 was applied, followed by the extraction of eight statistical features: mean, standard deviation, variance, skewness, kurtosis, interquartile range (IQR), root mean square (RMS), and zero crossing rate (ZCR). These features were classified using MLP, KNN, and SVM models. MLP and KNN achieved the highest accuracy of 92.46%, while SVM had lower accuracy (72.99%) but high recall (94.21%). The results demonstrate the effectiveness of wavelet-based statistical features for lightweight and accurate arrhythmia detection.

1. INTRODUCTION

Penyakit kardiovaskular merupakan penyebab utama kematian di dunia, dan aritmia jantung merupakan salah satu gangguan yang paling umum terjadi. **Aritmia** adalah kondisi dimana irama detak jantung menjadi tidak teratur (terlalu cepat, terlalu lambat, atau tidak beraturan) dan dapat menimbulkan komplikasi serius seperti stroke, gagal jantung dan bahkan kematian mendadak karena diderita oleh pasien secara jangka panjang. Oleh karena itu, deteksi aritmia secara dini dan akurat sangat penting untuk intervensi medis yang tepat waktu. Salah satu alat utama dalam diagnosis gangguan jantung adalah **elektrokardiogram (EKG)**, yang merekam aktivitas listrik jantung secara non-invasif. Meskipun demikian, interpretasi sinyal EKG secara manual

membutuhkan keahlian tinggi, bersifat subjektif, dan sangat memakan waktu, khususnya dalam konteks pemantauan jangka panjang.


Seiring dengan perkembangan teknologi komputasi, pendekatan otomatis berbasis **machine learning** dan **pengolahan sinyal** digital telah banyak digunakan untuk mendeteksi aritmia secara efisien. Beberapa penelitian terdahulu berfokus pada klasifikasi berbasis detak jantung (*beat-based classification*), dimana detak jantung manusia dikenali dan diklasifikasikan menggunakan fitur morfologis. Namun pendekatan ini sangat bergantung pada akurasi segmentasi sinyal, khususnya deteksi puncak “R” yang sering kali tidak stabil pada kondisi sinyal yang terlalu banyak gangguan. Sebagai solusi alternatif, pendekatan berbasis *windowing*, dimana sinyal dibagi kedalam segmen waktu. Tahapan *windowing* sangat disarankan karena lebih tahan terhadap gangguan dan tidak memerlukan deteksi puncak secara eksplisit. *Windowing* juga memungkinkan klasifikasi biner secara langsung terhadap segmen sinyal (misal dibagi dalam 1 detik), yang lebih praktis untuk implementasi sistem *real-time* dan *wearable monitoring*.

Salah satu teknik pengolahan sinyal yang efektif dalam menganalisis sinyal EKG yang bersifat non-stasioner adalah **transformasi wavelet diskrit (DWT)**. Wavelet memungkinkan analisis sinyal dalam domain waktu dan frekuensi secara simultan, serta mampu mengisolasi komponen frekuensi rendah dan tinggi yang penting untuk mengenali pola aritmia. Beberapa penelitian sebelumnya membahas klasifikasi aritmia pada sinyal EKG dengan mengkombinasikan *continuous wavelet transform* (CWT) dengan convolutional neural network (CNN) mencapai akurasi sebesar 98.7% menggunakan data *MIT-BIH Arrhythmia Database*. [1] Penelitian lainnya memanfaatkan DWT dan mengekstraksi delapan fitur statistik dari beberapa level dekomposisi wavelet, kemudian menggunakan algoritma *K-nearest neighbors* (KNN) dan *support vector machine* (SVM) untuk klasifikasi biner dengan akurasi hingga 96%. [2] Penelitian lain dengan memanfaatkan DWT dan *fast fourier transform* (FFT) untuk mereduksi sinyal EKG dengan efektif tereduksi, DWT berhasil secara visual untuk rekonstruksi sinyal yang tidak konstan. [3] Untuk mendeteksi dan klasifikasi atrial jantung juga dilakukan oleh peneliti lainnya dengan memanfaatkan ekstraksi fitur DWT dan morfologi EKG + PCA. [4] Penelitian yang sama juga telah dilakukan oleh Siti Agrippina Alodia Yusuf, dkk (2023), melakukan klasifikasi menggunakan KNN dengan ekstraksi fitur DWT level 2 dengan mempertimbangkan gelombang PQRS. [5]

Dalam penelitian ini, kami mengusulkan sistem klasifikasi biner untuk mendeteksi aritmia dari sinyal EKG menggunakan pendekatan *windowing* berbasis waktu, transformasi wavelet dan ekstraksi fitur statistik. Data sinyal EKG diperoleh dari *MIT-BIH Arrhythmia Database*, yang telah menjadi benchmark standar dalam penelitian biomedical signal processing. Dataset publik yang sudah disediakan secara online melalui situs website <https://www.physionet.org/content/mitdb/1.0.0/>. Proses *preprocessing* dilakukan dengan *Butterworth bandpass filter* orde ke-2 untuk menghindari adanya gangguan mulai dari frekuensi rendah hingga tinggi yang disebabkan oleh gangguan saluran listrik, *baseline wander*, gerakan tubuh, maupun gangguan yang timbul dari elektroda, [3], [6] dengan frekuensi *cut-off* disesuaikan untuk mempertahankan komponen jantung utama.

2. RESEARCH METHODS

Secara umum penelitian ini mengusulkan pendekatan berbasis klasifikasi biner untuk mendeteksi aritmia pada sinyal elektrokardiogram (EKG) melalui proses pengolahan sinyal dan ekstraksi fitur statistik dari *transformasi wavelet diskrit* (DWT). Tahapan yang dikerjakan seperti yang ditunjukkan pada metodologi penelitian pada gambar 1 berikut:



Gambar 1. Metodologi penelitian

1. Dataset EKG

Pada penelitian ini menggunakan dataset *MIT-BIH database (Arrhythmia database v1.0.0 PhysioNet)*. *MIT-BIH Arrhythmia Database* berisi data sinyal jantung EKG 2 saluran ambulatori dengan jenis kelainan jantung yang beragam yang mencakup sinyal detak jantung normal dan abnormal, tetapi hanya satu saluran yang digunakan dalam penelitian ini untuk konsistensi dan efisiensi pemrosesan. Database ini diambil dari 48 rekaman dari Rumah Sakit yang berada di Beth Israel, Boston yang sekarang berubah nama menjadi *Beth Israel Deaconess Medical Center*. Rekaman tersebut di digitalkan pada sampel 360 per detik per saluran dengan resolusi 11 bit pada rentang 10 mV.[7] Setiap rekaman memiliki panjang 650.000 sampel dan disertai anotasi beat dari pakar kardiologi. Untuk total detak jantung/*beat* yang dimiliki setiap rekaman tampak pada tabel 1 berikut:

Tabel 1. Jumlah detak jantung/*beat* dari 48 rekaman EKG MIT-BIH *Arrhythmia Database*

No	Rekaman ke-	Total Beat	No	Rekaman ke-	Total Beat
1	100	2274	25	201	2039
2	101	1874	26	202	2146
3	102	2192	27	203	3108
4	103	2091	28	205	2672
5	104	2311	29	207	2385
6	105	2691	30	208	3040
7	106	2098	31	209	3052
8	107	2140	32	210	2685
9	108	1824	33	212	2763
10	109	2535	34	213	3294
11	111	2133	35	214	2297
12	112	2550	36	215	3400
13	113	1796	37	217	2280
14	114	1890	38	219	2312
15	115	1962	39	220	2069
16	116	2421	40	221	2462
17	117	1539	41	222	2634
18	118	2301	42	223	2643
19	119	2094	43	228	2140
20	121	1876	44	230	2466
21	122	2479	45	231	2011
22	123	1519	46	232	1816
23	124	1634	47	233	3152
24	200	2792	48	234	2764

2. Filtering Sinyal

Sinyal asli EKG mengandung *noise*/gangguan frekuensi tinggi dan drift baseline frekuensi rendah. Pada penelitian ini mengacu tahapan *filtering* yang diterapkan oleh Xiaojun Zhou, dkk (2014), untuk menghilangkan gangguan pada saluran listrik menggunakan frekuensi maksimum 50 Hz, sedangkan untuk menghilangkan gangguan yang timbul akibat elektroda dengan frekuensi minimum 0.5 Hz. *Filtering* sinyal detak jantung menggunakan desain dari *filter butterworth* dengan tipe *bandpass filter* dan order *lowpass* ditentukan nilainya adalah 2 dari nilai default 5, formula *butterworth* dapat dilihat pada persamaan (1-2).

Filter *butterworth* orde ke-2 dirancang untuk memiliki respon frekuensi datar di *bandpass*-nya. Persamaan yang dapat digunakan seperti berikut:

$$H(s) = \frac{1}{\sqrt{1 + \left(\frac{s}{\omega_c}\right)^{2n}}} \quad (1)$$


Untuk implementasi digital (diskrit), menggunakan fungsi bentuk persamaan:

$$y[n] = b_0x[n] + b_1x[n-1] + b_2x[n-2] - a_1y[n-1] - a_2y[n-2] \quad (2)$$

Dengan $x[n]$ sinyal input dan $y[n]$ sinyal output. Koefisien a_i , b_i diperoleh dari desain filter digital berbasis transformasi bilinear.

3. Windowing dan Pelabelan

Selanjutnya, sinyal dibagi menjadi *window* sepanjang 360 sampel (1 detik) dengan overlap 100 sampel.[8] Untuk meningkatkan jumlah data penelitian dan ketahanan terhadap *overfitting*, maka menggunakan *overlap* sebesar 100 sampel antar *window* seperti diilustrasikan pada gambar 2.



Gambar 2. Ilustrasi *Windowing*

Setiap *window* diberi label sebagai **normal (N)** atau **abnormal (A)** berdasarkan metode voting mayoritas dari anotasi beat yang muncul dalam *window* tersebut. Jika lebih dari 50% beat dalam satu *window* berlabel normal, maka *window* tersebut dilabeli sebagai normal; sebaliknya, jika dominasi labelnya adalah beat abnormal, maka *window* dikategorikan sebagai abnormal.

4. Transformasi Wavelet

Setelah segmentasi, dilakukan DWT untuk mengekstrak komponen frekuensi penting dari setiap window. DWT menggunakan mother wavelet **symlet (sym8)**, yang merupakan varian simetris dari Daubechies dengan panjang filter yang lebih tinggi. Transformasi dilakukan hingga **level ke-4 (4-levels decomposition)**, [4] menghasilkan satu koefisien aproksimasi dan tiga koefisien detail utama yaitu A4, D2, D3, D4. Koefisien A4 merupakan aproksimasi level 4, mewakili tren umum dan komponen frekuensi rendah. Koefisien D4, D3 dan D2 merupakan detail pada level 2 hingga 4, mewakili komponen frekuensi menengah hingga tinggi yang penting untuk mendeteksi kompleksitas morfologi seperti QRS dan gelombang P/T.

Proses DWT dilakukan menggunakan bank *filter low-pass* dan *high-pass* seperti ditunjukkan pada persamaan (3) dengan *downsampling* 2x pada setiap level seperti ditunjukkan dengan persamaan (4).

Secara umum transformasi wavelet diskrit dapat dinyatakan dalam bentuk persamaan:

$$A_j[n] = \sum_k x[k] \cdot \phi_{j,k}[n], \quad D_j[n] = \sum_k x[k] \cdot \omega_{j,k}[n] \quad (3)$$

dengan:

- $x[k]$: sinyal input
- $\phi_{j,k}$: fungsi *scaling (low-pass filter)*
- $\omega_{j,k}$: fungsi wavelet (*high-pass filter*)
- j : level dekomposisi

Dalam implementasinya, sinyal melewati sepasang *filter: low-pass* untuk aproksimasi (A) dan *high-pass* untuk detail (D), diikuti oleh *downsampling*:

$$A_j[n] = \sum_m h[m] \cdot A_{j-1}[2n - m], \quad D_j[n] = \sum_m g[m] \cdot A_{j-1}[2n - m] \quad (4)$$

dengan:

- $g[m]$: koefisien *filter low-pass (scaling)* dari Sym8
- $h[m]$: koefisien *filter high-pass (wavelet)* dari Sym8

Dalam hal ini, sinyal $x[n]$ pada level awal (A0) di diseminasikan melalui transformasi hingga level A4. Semua koefisien hasil (A4, D4, D3, dan D2) digunakan dalam tahap ekstraksi fitur. Total fitur yang didapatkan hasil dari wavelet adalah 231 fitur untuk setiap *window* nya. Koefisien filter dari mother wavelet symlet memiliki morfologi periodik dan bersifat non-stasioner sehingga cocok untuk data EKG.

5. Ekstraksi Fitur Statistik

Dari setiap koefisien wavelet yang diperoleh setelah penggabungan (D2, D3, D4, A4) dilakukan ekstraksi delapan fitur statistik yang merepresentasikan karakter sinyal dalam aspek distribusi, bentuk dan kompleksitas. 8 Fitur statistik (*mean*, standar deviasi, varian, kurtosis, *skew*, *interquartile range*, *root mean square*, dan *zero-crossing rate*) tersebut direpresentasikan dengan persamaan (5-12).

a. Mean

$$\text{Formula pencarian: } \mu = \frac{1}{n} \sum_{i=1}^n c_i \quad (5)$$

b. Standard Deviation

$$\text{Formula pencarian: } \sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (c_i - \mu)^2} \quad (6)$$

c. Variance
Formula pencarian: $var = \sigma^2$ (7)

d. Skewness
Formula pencarian: $skew = \frac{1}{n} \sum_{i=1}^n \left(\frac{c_i - \mu}{\sigma} \right)^3$ (8)

e. Kurtosis
Formula pencarian: $kurtosis = \frac{1}{n} \sum_{i=1}^n \left(\frac{c_i - \mu}{\sigma} \right)^4$ (9)

f. Interquartile Range
Formula pencarian: $IQR = Q_3 - Q_1$ (10)

g. Root Mean Square
Formula pencarian: $RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n c_i^2}$ (11)

h. Zero-Crossing Rate
Formula pencarian: $ZCR = \frac{1}{n-1} \sum_{i=1}^{n-1} \mathbb{I}[(c_i \cdot c_{i+1}) < 0]$ (12)

Total terdapat 8 fitur dari setiap window, yang digunakan sebagai inputan ke algoritma klasifikasi.

6. Klasifikasi

Dari fitur yang telah di ekstrak selanjutnya digunakan untuk pelatihan dan pengujian algoritma klasifikasi biner, dengan target dua kelas: normal dan abnormal. Beberapa algoritma pembelajaran mesin umum dievaluasi, seperti: *Multi-layer perceptron* (MLP), KNN dan SVM. Setiap model dikonfigurasi, dilatih dan dievaluasi secara terpisah menggunakan teknik validasi silang. Data dibagi menjadi 2 yaitu data uji dan data latih dengan pembagian 80% digunakan untuk data latih dan 20% untuk data uji.

a. K-Nearest Neighbors (KNN)

KNN merupakan algoritma pembelajaran berbasis instance yang melakukan klasifikasi berdasarkan kemiripan fitur dengan sampel terdekat di ruang fitur.[5], [9] Setiap data uji di klasifikasikan dengan cara menghitung jarak (*Euclidean*) terhadap seluruh data pelatihan, lalu mengambil mayoritas label dari K tetangga terdekat dengan parameter yang digunakan K=5. Klasifikasi KNN mengacu pada persamaan (13)

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_j - x_{ij})^2} \quad (13)$$

dengan:

- x: data uji
- x_i : data pelatihan
- $d(x, x_i)$: jarak *Euclidean*

b. Support Vector Machine (SVM)

SVM bekerja dengan mencari hyperplane optimal yang memisahkan kelas normal dan abnormal dengan margin maksimum. Untuk menangani data non-linear, digunakan *kernel trick*, khususnya *Radian Basis Function* (RBF).[9], [10] Klasifikasi SVM mengacu persamaan (14)

$$K(x, x') = \exp(-\gamma \|x - x'\|^2) \quad (14)$$

dengan:

- γ : parameter kontrol untuk radius pengaruh data
- C: parameter penalti kesalahan klasifikasi

Optimalisasi dilakukan untuk memaksimalkan margin sambil meminimalkan kesalahan dengan persamaan (15)

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \varepsilon_i \quad (15)$$

dengan:

- w: bobot hyperplane
- ε_i : variabel slack (toleransi kesalahan klasifikasi)

c. *Multi-Layer Perceptron (MLP)*

Pada penelitian ini, MLP merupakan jaringan syaraf tiruan (*artificial neural network*) dengan lapisan input 32 neuron, hidden layer 128, dan iterasi sebanyak 300. MLP sangat cocok untuk dataset dengan relasi non-linear dan dapat mempelajari pola kompleks dari fitur wavelet-statistik. Persamaan MLP dapat dilihat pada persamaan (16)

$$\hat{y} = \sigma(W^{(2)} \cdot f(W^{(1)} \cdot x + b^{(1)}) + b^{(2)}) \quad (16)$$

dengan:

- x: vektor input
- W: matriks bobot
- b: vektor bias
- f: fungsi aktivasi

7. Evaluasi Model

Setiap model dievaluasi dengan teknik *hold-out validation*. Metrik evaluasi yang digunakan adalah:

a. Akurasi

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (17)$$

b. Presisi

$$Presisi = \frac{TP}{TP+FP} \quad (18)$$

c. Recall (Sensitivity)

$$Recall = \frac{TP}{TP+FN} \quad (19)$$

d. F1-Score


$$F1 = \frac{2 \cdot Precision \cdot Recall}{Precision+Recall} \quad (20)$$

3. RESULTS


Pada gambar 3, ditunjukkan ilustrasi sinyal asli hasil perekaman EKG selama 1 detik. Dapat dilihat bahwa sinyal masih memiliki banyak gangguan. Secara visual seperti tampak pada gambar 4, menunjukkan ilustrasi sinyal EKG setelah mengalami penyaringan *bandpass* dengan nilai minimum 0.5 Hz dan maksimum 50 Hz dengan N order 2.

Setelah sinyal EKG dari database MIT-BIH diproses melalui *filtering Butterworth* dan segmentasi *window* sepanjang 360 sampel (dengan *overlap* 100 sampel), dilakukan transformasi *Discrete Wavelet Transform (DWT)* menggunakan Symlet 8 (sym8) hingga level 4. Transformasi ini menghasilkan koefisien *approximation* dan detail yang menggambarkan berbagai skala frekuensi sinyal seperti tampak pada gambar 5.


Dikarenakan D1 memiliki detail yang sangat halus dan mewakili sinyal frekuensi yang sangat tinggi sehingga terlihat seperti banyak *noise*, maka koefisien D1 tidak diikutkan dalam proses ekstraksi fitur nantinya. Penelitian milik Arpita Paul, dkk (2023) juga menghilangkan frekuensi yang sangat tinggi pada D1 bahkan pada D2 untuk kesesuaian irama jantungnya.[11]



Gambar 3. Ilustrasi sinyal asli EKG 1 detik




Gambar 4. Ilustrasi Sinyal EKG setelah bandpass filter 0.5-50Hz, N order 2



Gambar 5. Detail koefisien dekomposisi wavelet 4 level dari sinyal EKG menggunakan fungsi sym8

Dari 48 rekaman yang di peroleh dari MIT-BIH didapatkan hasil *windowing* dengan label Normal sebanyak 207.613 *window*, sedangkan label Abnormal sebanyak 95.969 *window*. Data yang sudah terkumpul ini dilakukan tahapan selanjutnya yaitu ekstraksi fitur statistik. Selama eksperimen, dilakukan analisis terhadap distribusi fitur antar kelas untuk melihat sejauh mana fitur-fitur ini dapat membedakan sinyal normal dan abnormal.

Tiga model klasifikasi untuk pengujian model *K-Nearest Neighbors* (KNN), *Support Vector Machine* (SVM), dan *Multi-Layer Perceptron* (MLP) diterapkan pada penelitian ini mengacu pada persamaan (17-20). Evaluasi performa dilakukan dengan metode *hold-out validation*, dimana dataset dibagi secara acak menjadi: 80% data digunakan sebagai data pelatihan (*training set*) dan 20% data digunakan sebagai data pengujian (*testing set*). Evaluasi berfokus pada metrik akurasi, presisi, *recall*, dan *F1-score*, serta visualisasi menggunakan *confusion matrix* yang ditunjukkan pada gambar 6.



Gambar 6 Tabel Konfusi model klasifikasi (a) SVM; (b) MLP; dan (c) KNN

Tabel 3. Performa hasil klasifikasi hold-out validation dengan fitur statistik wavelet

Pengklasifikasi	Akurasi	Presisi	Recall	F1-Score
KNN	0.9246	0.9167	0.9786	0.9467
SVM[9]	0.7299	0.7365	0.9421	0.8267
MLP	0.9246	0.9167	0.9786	0.9467

Mengacu tabel 3, model MLP menunjukkan kinerja terbaik secara keseluruhan dalam eksperimen ini. Dengan akurasi 92.46%, presisi 91.67%, recall 97.86%, dan F1-Score 94.67%. Menariknya, model KNN menghasilkan performa identik dengan MLP dalam eksperimen ini. Hal ini menunjukkan bahwa fitur-fitur statistik yang di ekstrak cukup representatif sehingga model sederhana seperti KNN dapat memisahkan data normal dan abnormal secara efektif. Untuk model SVM menghasilkan akurasi yang rendah yaitu 72.99% meskipun recall sangat tinggi sebesar 94.21%, hal ini dinilai cukup handal untuk mendeteksi aritmia positif, namun kesalahan klasifikasi normal banyak kesalahan sehingga menyebabkan presisi menurun ke 73.65%. Nilai F1-Score 82.67% pada SVM masih menunjukkan performa yang layak, namun tertinggal jauh dibandingkan MLP dan KNN.

4. DISCUSSION

Dari hasil eksperimen, dapat disimpulkan bahwa:

- MLP dan KNN memberikan performa yang unggul, menunjukkan bahwa meskipun fitur yang digunakan cukup sederhana (statistik dari wavelet), model klasifikasi tersebut dapat memberikan representasi sinyal yang sangat informatif.
- SVM cenderung terlalu sensitif terhadap aritmia, menyebabkan banyak false positive. Model ini lebih cocok digunakan apabila deteksi aritmia dianggap lebih penting daripada kesalahan dalam mendeteksi sinyal normal.
- Transformasi wavelet Symlet 8 level 4 efektif dalam menyiapkan sinyal untuk klasifikasi berbasis fitur statistik.
- Fitur-fitur statistik yang digunakan cukup ringan dan komputasional yang efisien, membuat metode ini potensial untuk diterapkan pada perangkat pemantauan jantung portabel atau sistem mHealth berbasis embedded.

5. CONCLUSIONS AND RECOMMENDATIONS

Penelitian ini berhasil mengembangkan sistem klasifikasi biner untuk mendeteksi aritmia pada sinyal EKG dengan pendekatan ekstraksi fitur statistik berbasis transformasi wavelet. Transformasi wavelet symlet 8 level 4 mampu memisahkan informasi waktu-frekuensi dari sinyal EKG secara efektif, sehingga fitur statistik dapat menangkap pola yang relevan. Ekstraksi fitur tersebut meliputi *mean*, standar deviasi, varian, *skewness*, kurtosis, IQR, RMS, dan ZCR. Dari ketiga model klasifikasi yang dievaluasi, MLP dan KNN menunjukkan kinerja terbaik dengan akurasi dan F1-score yang tinggi, meskipun SVM memiliki recall tinggi.

Berdasarkan hasil dan analisis yang telah dilakukan, penulis memberikan beberapa rekomendasi pengembangan untuk penelitian selanjutnya:

- Meningkatkan model klasifikasi dengan melakukan tuning parameter maupun menggunakan model yang lainnya.
- Penambahan fitur temporal dengan mengintegrasikan dengan fitur statistik.
- Penelitian ini masih terbatas pada klasifikasi biner, sehingga dapat diperluas ke multi kelas.
- Melakukan pengujian dengan dunia nyata atau *real-time*.
- Mengimplementasikan dengan sistem embedded.

FUNDING

Penelitian ini dibiayai oleh **LPPM Universitas Widya Husada Semarang**.

REFERENCES

- [1] T. Wang, C. Lu, Y. Sun, M. Yang, C. Liu, and C. Ou, "Automatic ECG Classification Using Continuous Wavelet Transform and Convolutional Neural Network," *Entropy*, vol. 23, no. 1, p. 119, Jan. 2021, doi: 10.3390/e23010119.
- [2] M. Maleki and F. Haeri, "Identification of cardiovascular diseases through ECG classification using wavelet transformation," Aug. 2024, [Online]. Available: <http://arxiv.org/abs/2404.09393>
- [3] Rasyida Shabihah Zukro Aini and Elsa Sari Hayunah Nurdiniyah, "Effectiveness of Wavelet and Fourier Transform Methods for Denoising ECG Apnea Signals," *BEST J. Appl. Electr. Sci. Technol.*, vol. 5, no. 2, pp. 76–80, Sep. 2023, doi: 10.36456/best.vol5.no2.8765.
- [4] H. Yang and Z. Wei, "A Novel Approach for Heart Ventricular and Atrial Abnormalities Detection via an Ensemble Classification Algorithm Based on ECG Morphological Features," *IEEE Access*, vol. 9, pp. 54757–54774, 2021, doi: 10.1109/ACCESS.2021.3071273.
- [5] Siti Agrippina Alodia Yusuf, Nani Sulistianingsih, and Helmi Imaduddin, "EKSTRASI FITUR SINYAL EKG MYOCARDIAL INFARCTIN MENGGUNAKAN DISCRETE WAVELET TRANSFORMATION," *Tek. Teknol. Inf. dan Multimed.*, vol. 4, no. 1, pp. 38–44, Jun. 2023, doi: 10.46764/teknimedia.v4i1.96.
- [6] X. Zhou, X. Ma, and Y. Li, "An adaptive threshold algorithm based on wavelet in QRS detection," in *2014 International Conference on Audio, Language and Image Processing*, Jul. 2014, pp. 858–862. doi: 10.1109/ICALIP.2014.7009917.
- [7] A. L. Goldberger *et al.*, "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. E215–20, Jun. 2000, doi: 10.1161/01.cir.101.23.e215.
- [8] D. Nurdiah, E. M. Yuniarno, S. A. Wulandari, Y. K. Surapto, and M. H. Purnomo, "Deep Semantic Feature Extraction to Overcome Overlapping Frequencies for Instrument Recognition in Indonesian Traditional Music Orchestras," *IEEE Access*, vol. 12, pp. 76936–76954, 2024, doi: 10.1109/ACCESS.2024.3401699.
- [9] D. T. Nugraha *et al.*, "Efek Transformasi Wavelet Diskrit Pada Klasifikasi Aritmia Dari Data Elektrokardiogram Menggunakan Machine Learning," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. 1, p. 13, Jan. 2023, doi: 10.30865/mib.v7i1.4859.
- [10] I. WIJAYANTO, A. HUMAIRANI, A. RIZAL, and S. HADIYOSO, "Klasifikasi Sinyal EKG menggunakan Ciri Statistik dan Parameter Hjorth dengan SVM dan k-NN," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 1, p. 132, Jan. 2022, doi: 10.26760/elkomika.v10i1.132.
- [11] A. Paul *et al.*, "Development Of Automated Cardiac Arrhythmia Detection Methods Using Single Channel ECG Signal," Jul. 2023, [Online]. Available: <http://arxiv.org/abs/2308.02405>