



Pengaruh Variasi Ukuran Jendela terhadap Kinerja Klasifikasi Aritmia Berbasis EKG

Indra Abdam Muwakhid^{1*}, Dewi Nurdiah²

¹ Program Studi Informatika Medis, Universitas Widya Husada Semarang, Indonesia

² Program Studi Teknik Informatika, Universitas Semarang, Indonesia

Email: abdam.stiess@gmail.com ^{1*}, nurdiah@usm.ac.id ²

*Penulis Korespondensi: abdam.stiess@gmail.com

Abstract. *Arrhythmia detection using electrocardiogram (ECG) signals requires an appropriate segmentation strategy to optimally represent cardiac morphological information. Although time-based windowing is widely applied in automated detection systems, the impact of window size variation on classification performance has not been systematically investigated. This study aims to evaluate the influence of different window sizes on arrhythmia detection performance using the K-Nearest Neighbors (KNN) algorithm. The dataset consists of 48 records from the MIT-BIH Arrhythmia Database sampled at 360 Hz. ECG signals were preprocessed using a 0.5–50 Hz bandpass filter and segmented with window sizes of 180, 360, 720, and 1000 samples using 50% overlap. Time-domain statistical features were extracted and used as input to the classification model. Experimental results indicate that the 180-sample window achieved the best performance, with an accuracy of 89.58% and an F1-score of 83.27%. These findings suggest that shorter segmentation windows increase training data density and are more suitable for distance-based classifiers such as KNN. This study highlights that window size selection is a critical parameter in arrhythmia detection system design and should be aligned with the characteristics of the classification algorithm employed.*

Keywords: *Arrhythmia; ECG; KNN; Signal Segmentation; Window Size.*

Abstrak. Deteksi aritmia berbasis sinyal elektrokardiogram (EKG) memerlukan strategi segmentasi yang tepat agar informasi morfologi jantung dapat direpresentasikan secara optimal. Meskipun teknik *windowing* berbasis waktu banyak digunakan dalam sistem deteksi otomatis, pengaruh variasi ukuran window terhadap performa klasifikasi belum banyak dianalisis secara sistematis. Penelitian ini bertujuan untuk mengevaluasi dampak variasi ukuran window terhadap kinerja deteksi aritmia menggunakan algoritma K-Nearest Neighbors (KNN). Dataset yang digunakan adalah 48 rekaman *MIT-BIH Arrhythmia Database* dengan frekuensi sampling 360 Hz. Sinyal dipra-proses menggunakan *bandpass filter* 0,5–50 Hz, kemudian disegmentasi dengan variasi ukuran 180, 360, 720, dan 1000 sampel dengan *overlap* 50%. Fitur domain waktu diekstraksi dan digunakan sebagai masukan model klasifikasi. Hasil eksperimen menunjukkan bahwa ukuran window 180 sampel menghasilkan performa terbaik dengan akurasi 89,6% dan F1-score 83,3%. Temuan ini menunjukkan bahwa segmentasi pendek meningkatkan kepadatan data pelatihan dan lebih sesuai untuk algoritma berbasis jarak seperti KNN. Penelitian ini menegaskan bahwa pemilihan ukuran window merupakan parameter penting dalam desain sistem deteksi aritmia dan harus disesuaikan dengan karakteristik algoritma klasifikasi yang digunakan.

Kata kunci: Aritmia; EKG; KNN; Segmentasi Sinyal; Ukuran Window.

1. LATAR BELAKANG

Penyakit kardiovaskular masih menjadi penyebab utama kematian di dunia, dengan gangguan irama jantung (aritmia) sebagai salah satu kondisi yang paling sering ditemukan pada pasien dengan penyakit jantung kronis. Aritmia ditandai dengan ketidakaturan denyut jantung yang dapat bersifat terlalu cepat, terlalu lambat, maupun tidak beraturan, dan berpotensi menyebabkan komplikasi serius seperti stroke, gagal jantung, hingga kematian mendadak apabila tidak terdeteksi secara dini dan akurat (Battineni et al., 2021; Vásquez-Iturralde et al., 2024).

Elektrokardiogram (EKG) merupakan metode standar yang digunakan untuk merekam aktivitas listrik jantung secara non-invasif dan menjadi alat utama dalam diagnosis aritmia. Namun demikian, interpretasi sinyal EKG secara manual memerlukan keahlian klinis yang tinggi dan waktu analisis yang panjang, terutama pada data pemantauan jangka panjang. Oleh karena itu, pengembangan sistem deteksi aritmia otomatis berbasis pengolahan sinyal dan pembelajaran mesin menjadi topik penelitian yang terus berkembang dalam bidang biomedical signal processing (Goldberger et al., 2000; Jambukia et al., 2018).

Salah satu tahapan penting dalam sistem deteksi aritmia otomatis adalah proses segmentasi sinyal EKG. Segmentasi umumnya dilakukan dengan membagi sinyal kontinu menjadi potongan sinyal berdurasi tertentu yang dikenal sebagai windowing. Pendekatan windowing berbasis waktu banyak digunakan karena lebih sederhana, tidak selalu bergantung pada deteksi puncak R, serta lebih tahan terhadap gangguan noise dibandingkan pendekatan berbasis detak jantung (beat-based) (Murat et al., 2020). Windowing juga memungkinkan pemrosesan sinyal secara real-time dan lebih sesuai untuk implementasi pada sistem pemantauan kesehatan berbasis perangkat wearable (Potharaju et al., 2025).

Meskipun teknik windowing telah banyak diterapkan, pemilihan ukuran window masih menjadi permasalahan yang belum memiliki standar baku. Ukuran window yang terlalu pendek dapat menyebabkan hilangnya informasi morfologi penting pada sinyal EKG, sedangkan ukuran window yang terlalu panjang berpotensi memasukkan informasi yang tidak relevan serta meningkatkan kompleksitas komputasi (Llamedo & Martínez, 2011; Potharaju et al., 2025). Beberapa penelitian sebelumnya menggunakan ukuran window tetap, seperti 1 detik atau 2 detik, tanpa melakukan analisis lebih lanjut mengenai pengaruh variasi ukuran window terhadap performa sistem klasifikasi aritmia (Acharya et al., 2017).

Perbedaan ukuran window secara langsung memengaruhi jumlah sampel, karakteristik fitur yang dihasilkan, serta kemampuan model klasifikasi dalam mengenali pola sinyal EKG normal dan abnormal. Oleh karena itu, evaluasi sistematis terhadap variasi ukuran window menjadi penting untuk menentukan konfigurasi segmentasi yang optimal dan seimbang antara akurasi deteksi serta efisiensi komputasi (Malik et al., 2022).

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menganalisis pengaruh variasi ukuran window terhadap performa deteksi aritmia berbasis sinyal EKG. Beberapa ukuran window yang berbeda dievaluasi dan dibandingkan menggunakan algoritma klasifikasi yang sama, sehingga dapat diketahui ukuran window yang paling optimal dalam menghasilkan akurasi, recall, dan F1-score terbaik. Hasil penelitian ini diharapkan dapat

menjadi acuan dalam perancangan sistem deteksi aritmia otomatis yang lebih efektif dan efisien, khususnya untuk aplikasi klinis dan pemantauan kesehatan berbasis teknologi digital.

2. KAJIAN TEORITIS

Sinyal Elektrokardiogram (EKG) dan Karakteristik Non-Stasioner

Sinyal elektrokardiogram (EKG) merepresentasikan aktivitas listrik jantung yang bersifat non-stasioner, dimana karakteristik frekuensi dan amplitudo berubah terhadap waktu. Sifat non-stasioner ini menyebabkan analisis sinyal EKG memerlukan pendekatan segmentasi agar informasi morfologi seperti gelombang P, kompleks QRS, dan gelombang T dapat dianalisis secara lokal dalam rentang waktu tertentu (Hussein et al., 2025). Penelitian terkini menunjukkan bahwa pendekatan segmentasi sinyal berbasis waktu lebih stabil terhadap gangguan noise dan pergeseran baseline dibandingkan pendekatan berbasis deteksi puncak secara langsung (Shan et al., 2023).

Segmentasi Sinyal Berbasis Windowing

Segmentasi sinyal EKG merupakan tahap awal yang krusial sebelum proses ekstraksi fitur dan klasifikasi. Salah satu pendekatan yang banyak digunakan adalah windowing berbasis waktu, yaitu membagi sinyal kontinu menjadi potongan berdurasi tertentu. Metode ini dinilai lebih stabil dibandingkan segmentasi berbasis deteksi puncak R karena tidak bergantung pada ketepatan algoritma deteksi detak jantung yang rentan terhadap noise (Song & Lee, 2024).

Pendekatan windowing juga memungkinkan pemrosesan sinyal secara berkelanjutan (streaming) dan sesuai untuk implementasi pada sistem pemantauan kesehatan real-time. Studi terbaru menunjukkan bahwa windowing berbasis waktu lebih adaptif terhadap variasi sinyal pasien dibandingkan metode berbasis beat detection (Niroshana et al., 2023).

Pengaruh Ukuran Window terhadap Representasi Informasi Sinyal

Ukuran window secara langsung memengaruhi jumlah informasi morfologi yang tertangkap dalam satu segmen sinyal. Window yang terlalu kecil berpotensi kehilangan pola lengkap dari kompleks QRS, sedangkan window yang terlalu besar dapat mencampurkan beberapa pola detak jantung yang berbeda sehingga mengaburkan karakteristik kelas sinyal. Penelitian oleh (Niroshana et al., 2023) menunjukkan bahwa variasi ukuran window memiliki dampak signifikan terhadap performa klasifikasi sinyal EKG, terutama pada metode berbasis pembelajaran mesin.


Klasifikasi Aritmia Berbasis Machine Learning

Metode pembelajaran mesin seperti K-Nearest Neighbors (KNN), Decision Tree, dan Support Vector Machine (SVM) masih banyak digunakan dalam klasifikasi aritmia karena

kesederhanaan implementasi dan efisiensi komputasi. Dalam beberapa penelitian terbaru, performa model klasifikasi sangat dipengaruhi oleh kualitas segmentasi sinyal sebelum tahap ekstraksi fitur, sehingga pemilihan ukuran window menjadi faktor krusial dalam pipeline sistem deteksi aritmia (Sahoo et al., 2020; V S. & R., 2024).

3. METODE PENELITIAN

Secara umum penelitian ini mengusulkan pendekatan untuk mendeteksi aritmia pada sinyal elektrokardiogram (EKG) dengan tahapan ditunjukkan seperti pada gambar 1.



Gambar 1. Alur Penelitian.

Dataset Sinyal EKG

Penelitian ini menggunakan MIT-BIH Arrhythmia Database yang tersedia secara publik melalui PhysioNet dan telah menjadi benchmark internasional dalam penelitian pengolahan sinyal EKG (Goldberger et al., 2000). Basis data ini terdiri dari 48 rekaman sinyal EKG dua kanal yang direkam dari pasien di Beth Israel Hospital, Boston, dengan frekuensi sampling 360 Hz dan resolusi 11-bit pada rentang ± 10 mV. Setiap rekaman disertai anotasi denyut jantung (beat annotation) yang diberikan oleh ahli kardiologi.

Penggunaan MIT-BIH pada penelitian ini bertujuan untuk memastikan reproduibilitas eksperimen serta memungkinkan perbandingan hasil dengan penelitian-penelitian sebelumnya yang menggunakan dataset serupa (Moody & Mark, 2001), sebagai rincian dataset di tuangkan dalam tabel 1 (Indra Abdam Muwakhid, 2025).

Tabel 1. Total Beat dan Data Aritmia dari 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

Pra-pemrosesan Sinyal (Preprocessing)

Sinyal EKG mentah mengandung berbagai gangguan seperti *baseline wander*, *power line interference*, dan *muscle artifact noise*. Untuk meminimalkan gangguan tersebut, diterapkan bandpass filter Butterworth orde dua dengan batas frekuensi 0,5–50 Hz. Rentang ini dipilih karena mampu mempertahankan komponen frekuensi utama sinyal jantung sekaligus menghilangkan gangguan frekuensi rendah dan tinggi yang tidak relevan (Shan et al., 2023).

Pendekatan ini banyak digunakan dalam penelitian EKG karena memiliki respon frekuensi yang datar pada daerah passband serta stabil secara numerik pada implementasi digital (Indra Abdan Muwakhid, 2025).

Segmentasi Sinyal Berbasis Variasi Ukuran Window

Tahapan utama dalam penelitian ini adalah proses segmentasi sinyal EKG menggunakan teknik *windowing* berbasis waktu. Berbeda dengan pendekatan berbasis detak jantung (*beat-based segmentation*) yang bergantung pada deteksi puncak R, pendekatan *windowing* lebih sederhana dan lebih sesuai untuk implementasi sistem real-time serta perangkat wearable (Song & Lee, 2024).

Untuk menganalisis pengaruh ukuran window terhadap performa klasifikasi aritmia, digunakan empat variasi ukuran window sebagai berikut:

- 180 sampel ($\approx 0,5$ detik)
- 360 sampel (≈ 1 detik)
- 720 sampel (≈ 2 detik)
- 1000 sampel ($\approx 2,78$ detik)

Setiap window diberi overlap sebesar 50% untuk menjaga kontinuitas informasi antar segmen serta meningkatkan jumlah sampel data pelatihan (Potharaju et al., 2025).

Pelabelan window dilakukan menggunakan metode majority voting berdasarkan anotasi beat yang berada di dalam rentang window. Jika lebih dari 50% anotasi dalam window berlabel abnormal, maka window tersebut dikategorikan sebagai abnormal, dan sebaliknya.

Ekstraksi Fitur Sinyal

Untuk menjaga fokus penelitian pada pengaruh ukuran window, fitur yang digunakan dibuat sederhana dan konsisten pada semua skenario. Dari setiap window diekstraksi fitur domain waktu yang umum digunakan dalam analisis sinyal fisiologis, yaitu: *Mean*, *Standard deviation*, *Root mean square* (RMS), *Skewness*, *Kurtosis*.

Fitur domain waktu dipilih karena ringan secara komputasi dan telah terbukti mampu merepresentasikan karakteristik dasar sinyal EKG tanpa memerlukan transformasi kompleks (Llamedo & Martínez, 2011).

Klasifikasi Aritmia

Fitur yang diperoleh selanjutnya digunakan sebagai masukan ke algoritma klasifikasi *K-Nearest Neighbors* (KNN) dengan parameter $K=5$ dan metrik jarak *Euclidean*. KNN dipilih karena sifatnya yang sederhana, tidak memerlukan proses pelatihan kompleks, serta sering digunakan sebagai *baseline classifier* dalam penelitian *biomedical signal processing* (Indra Abdan Muwakhid, 2025; Siahaan et al., 2026).

Pada setiap variasi ukuran window, proses klasifikasi dilakukan dengan skema pembagian data: 80% data latih (training set), 20% data uji (testing set).

Metrik Evaluasi

Performa klasifikasi dievaluasi menggunakan metrik standar yang umum digunakan dalam penelitian deteksi aritmia, yaitu: Akurasi (Accuracy), Presisi (Precision), Recall (Sensitivity), F1-Score.

Metrik ini memberikan gambaran menyeluruh mengenai kemampuan sistem dalam membedakan sinyal normal dan abnormal (Malik et al., 2022).

4. HASIL DAN PEMBAHASAN


Hasil Segmentasi Berdasarkan Variasi Window


Proses segmentasi sinyal EKG menjadi tahapan fundamental sebelum dilakukan ekstraksi fitur dan klasifikasi. Pada penelitian ini, segmentasi dilakukan menggunakan pendekatan time-based windowing dengan empat variasi ukuran window, yaitu 180, 360, 720, dan 1000 sampel, dengan overlap sebesar 50%. Variasi ukuran ini menghasilkan jumlah segmen (window) yang berbeda secara signifikan dari rekaman sinyal yang sama.

Secara matematis, jumlah window yang dihasilkan dari suatu sinyal dengan panjang N sampel, ukuran window W , dan overlap O , dapat dinyatakan dengan rumus (1):

$$\text{Jumlah Window} = \frac{N-W}{W-O} + 1 \quad (1)$$

Dengan nilai overlap ditetapkan sebesar 50% ($O = \frac{W}{2}$), maka semakin kecil nilai W , semakin besar jumlah window yang terbentuk. Berikut contoh segmentasi yang di hasilkan dari salah satu sinyal dengan ukuran window 180, 360, 720, dan 1000 sampel yang ditunjukkan pada gambar 2.






Gambar 2. Sampel segmentasi dengan berbagai ukuran window.

Fenomena ini bukan sekadar konsekuensi teknis segmentasi, melainkan memiliki implikasi langsung terhadap kepadatan data latih (data density) yang digunakan dalam proses klasifikasi. Window berukuran kecil menghasilkan jumlah sampel pelatihan yang sangat banyak, namun setiap segmen hanya merepresentasikan sebagian kecil dari morfologi denyut jantung. Sebaliknya, window berukuran besar menghasilkan representasi sinyal yang lebih utuh, tetapi jumlah sampel pelatihan menjadi lebih sedikit.

Secara eksperimental, kecenderungan jumlah window yang dihasilkan dapat diilustrasikan pada Gambar 3 berikut:



Gambar 3. Perbandingan jumlah window yang di hasilkan pada setiap variasi ukuran *window*.

Selain jumlah segmen, variasi ukuran window juga memengaruhi proporsi distribusi label (normal vs abnormal) pada dataset hasil segmentasi. *Window* yang terlalu kecil cenderung menghasilkan segmen yang hanya memuat sebagian morfologi gelombang EKG (misalnya hanya QRS saja tanpa P dan T), sehingga proses pelabelan berbasis *majority voting* menjadi kurang representatif terhadap kondisi ritme jantung secara utuh. Sebaliknya, window yang lebih panjang mampu mencakup satu hingga dua siklus denyut jantung lengkap (P–QRS–T), sehingga pelabelan menjadi lebih stabil dan merepresentasikan kondisi fisiologis yang lebih akurat.

Temuan ini sejalan dengan penelitian Indra Abdam M., dkk yang menyatakan bahwa segmentasi sinyal berbasis waktu harus cukup panjang untuk mempertahankan struktur morfologi denyut jantung secara utuh, namun tidak terlalu panjang sehingga mengurangi jumlah sampel pelatihan secara signifikan (Indra Abdam Muwakhid, 2025). Untuk mengetahui hasil analisis perubahan ukuran *window* dengan jumlah *window* yang di dapatkan beserta hasil deteksi bisa di lihat pada Tabel 2 berikut:

Tabel 2. Analisis Perubahan Ukuran *Window*.

Ukuran <i>Window</i>	Jumlah <i>Window</i>	Normal	Abnormal
180	346608	149605	71169
360	173280	118001	50633
720	86592	61183	25311
1000	62304	44157	18121

Dengan demikian, dapat disimpulkan bahwa variasi ukuran *window* secara langsung memengaruhi dua aspek krusial dalam sistem deteksi aritmia, yaitu kuantitas data pelatihan yang tersedia untuk model pembelajaran mesin, dan kualitas representasi morfologi sinyal di dalam setiap segmen.

Terlihat bahwa jumlah *window* menurun hampir secara proporsional terhadap peningkatan ukuran segmentasi. *Window* 180 sampel menghasilkan 346.608 segmen, sedangkan *window* 1000 sampel hanya menghasilkan 62.304 segmen. Penurunan ini terjadi karena peningkatan ukuran *window* secara langsung mengurangi jumlah langkah segmentasi yang dapat dilakukan sepanjang sinyal.

Secara matematis, dengan *overlap* 50%, jumlah *window* berbanding terbalik dengan panjang segmentasi. Oleh karena itu, *window* 180 sampel menghasilkan hampir 5,56 kali lebih banyak data dibanding *window* 1000 sampel.

Namun demikian, jumlah total window bukan satu-satunya parameter yang relevan. Distribusi label juga mengalami perubahan yang menarik. Apabila dihitung proporsinya terhadap total window:

- *Window* 180 → $\pm 43,1\%$ normal dan $\pm 20,5\%$ abnormal
- *Window* 360 → $\pm 68,1\%$ normal dan $\pm 29,2\%$ abnormal
- *Window* 720 → $\pm 70,7\%$ normal dan $\pm 29,2\%$ abnormal
- *Window* 1000 → $\pm 70,9\%$ normal dan $\pm 29,1\%$ abnormal

Terlihat bahwa pada *window* 180 sampel, proporsi segmen yang berhasil terlabel relatif lebih kecil dibanding ukuran lainnya. Hal ini menunjukkan bahwa banyak *window* pendek tidak mengandung cukup anotasi beat untuk dilakukan pelabelan mayoritas secara stabil.

Analisis Performa Klasifikasi Berdasarkan Variasi Ukuran *Window*

Setelah proses segmentasi dan ekstraksi fitur dilakukan pada setiap variasi ukuran *window*, tahap selanjutnya adalah evaluasi performa klasifikasi menggunakan algoritma *K-Nearest Neighbors* (KNN) dengan parameter $K=5$. Pembagian dataset dilakukan dengan skema 80% data latih dan 20% data uji pada setiap konfigurasi ukuran *window*.

Hasil evaluasi dirangkum pada Tabel 3.

Tabel 3. Performa klasifikasi berdasarkan variasi ukuran *window*.

Ukuran Window	Akurasi	Presisi	Recall	F1-Score
180	0,896	0,863	0,805	0,833
360	0,872	0,799	0,766	0,782
720	0,869	0,794	0,746	0,769
1000	0,889	0,826	0,782	0,804

Berbeda dengan asumsi umum bahwa *window* lebih panjang akan selalu meningkatkan performa klasifikasi, hasil eksperimen menunjukkan bahwa *window* 180 sampel ($\sim 0,5$ detik) justru menghasilkan akurasi tertinggi (89,6%) dan F1-score tertinggi (83,3%).

Sebaliknya, performa mengalami penurunan pada *window* 360 dan 720 sampel, sebelum kembali sedikit meningkat pada *window* 1000 sampel. Pola ini menunjukkan bahwa hubungan antara ukuran *window* dan performa klasifikasi tidak bersifat linear.

5. KESIMPULAN DAN SARAN

Kesimpulan

Penelitian ini bertujuan untuk menganalisis pengaruh variasi ukuran *window* terhadap performa deteksi aritmia berbasis sinyal elektrokardiogram (EKG) menggunakan algoritma *K-Nearest Neighbors* (KNN). Empat variasi ukuran segmentasi diuji, yaitu 180, 360, 720, dan 1000 sampel, dengan *overlap* sebesar 50%.

Hasil eksperimen menunjukkan bahwa ukuran *window* memiliki pengaruh signifikan terhadap performa klasifikasi. *Window* berukuran 180 sampel ($\approx 0,5$ detik) menghasilkan performa terbaik dengan akurasi sebesar 89,58% dan F1-score sebesar 83,27%. Temuan ini

menunjukkan bahwa segmentasi pendek mampu menghasilkan kepadatan data pelatihan yang tinggi, sehingga meningkatkan efektivitas algoritma berbasis jarak seperti KNN.

Sebaliknya, peningkatan ukuran *window* tidak selalu meningkatkan performa. *Window* berukuran lebih panjang cenderung menghasilkan jumlah segmen yang lebih sedikit serta meningkatkan homogenitas fitur antar kelas, sehingga menurunkan daya diskriminatif model.

Dengan demikian, dapat disimpulkan bahwa pemilihan ukuran *window* merupakan parameter krusial dalam sistem deteksi aritmia otomatis dan harus disesuaikan dengan karakteristik algoritma klasifikasi yang digunakan. Untuk algoritma KNN, ukuran *window* yang lebih pendek terbukti memberikan keseimbangan optimal antara jumlah data dan kemampuan generalisasi model.

Saran

Berdasarkan hasil penelitian yang telah dilakukan, beberapa saran untuk pengembangan penelitian selanjutnya adalah sebagai berikut:

- Melakukan evaluasi terhadap algoritma klasifikasi lain seperti *Support Vector Machine*, *Random Forest*, atau metode berbasis *Deep Learning* untuk mengetahui apakah tren performa terhadap variasi ukuran *window* menunjukkan pola yang serupa.
- Menguji variasi tingkat overlap segmentasi guna menganalisis pengaruh redundansi data terhadap performa klasifikasi.
- Melakukan pengujian menggunakan pendekatan *cross-validation* untuk meningkatkan *robustnes evaluasi performa*.
- Mengembangkan klasifikasi multi-kelas berdasarkan standar AAMI guna mengevaluasi sensitivitas sistem terhadap variasi jenis aritmia yang lebih kompleks.
- Menguji sistem pada skenario *real-time processing* atau perangkat berbasis *wearable* untuk menilai efisiensi komputasi dan stabilitas performa dalam kondisi praktis.

Dengan pengembangan lebih lanjut, pendekatan segmentasi optimal ini diharapkan dapat berkontribusi dalam perancangan sistem deteksi aritmia yang lebih adaptif, efisien, dan aplikatif dalam bidang kesehatan digital.

DAFTAR REFERENSI

- Acharya, U. R., Fujita, H., Lih, O. S., Hagiwara, Y., Tan, J. H., & Adam, M. (2017). Automated detection of arrhythmias using different intervals of tachycardia ECG segments with convolutional neural network. *Information Sciences*, 405, 81–90. <https://doi.org/10.1016/j.ins.2017.04.012>
- Battineni, G., Sagaro, G. G., Chintalapudi, N., & Amenta, F. (2021). The benefits of telemedicine in personalized prevention of cardiovascular diseases (CVD): A systematic review. *Journal of Personalized Medicine*, 11(7), 658. <https://doi.org/10.3390/jpm11070658>
- Goldberger, A. L., Amaral, L. A. N., Glass, L., Hausdorff, J. M., Ivanov, P. C., Mark, R. G., Mietus, J. E., Moody, G. B., Peng, C.-K., & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet. *Circulation*, 101(23). <https://doi.org/10.1161/01.CIR.101.23.e215>
- Hussein, O., Jameel, S. M., Altmemi, J. M., Abbas, M. A., Uğurenver, A., Alkubaisi, Y. M., & Sabry, A. H. (2025). Improving automated labeling with deep learning and signal segmentation for accurate ECG signal analysis. *Service Oriented Computing and Applications*, 19(2), 93–106. <https://doi.org/10.1007/s11761-024-00436-5>
- Indra Abdam Muwakhid. (2025). Statistical feature extraction based on wavelet transform for arrhythmia detection. *Jurnal Transformatika*, 23(1), 30–40. <https://doi.org/10.26623/transformatika.v23i1.12339>
- Jambukia, S. H., Dabhi, V. K., & Prajapati, H. B. (2018). ECG beat classification using machine learning techniques. *International Journal of Biomedical Engineering and Technology*, 26(1), 32. <https://doi.org/10.1504/IJBET.2018.089255>
- Llamedo, M., & Martínez, J. P. (2011). Heartbeat classification using feature selection driven by database generalization criteria. *IEEE Transactions on Biomedical Engineering*, 58(3), 616–625. <https://doi.org/10.1109/TBME.2010.2068048>
- Malik, J., Devocioglu, O. C., Kiranyaz, S., Ince, T., & Gabbouj, M. (2022). Real-time patient-specific ECG classification by 1D self-operational neural networks. *IEEE Transactions on Biomedical Engineering*, 69(5), 1788–1801. <https://doi.org/10.1109/TBME.2021.3135622>
- Moody, G. B., & Mark, R. G. (2001). The impact of the MIT-BIH Arrhythmia Database. *IEEE Engineering in Medicine and Biology Magazine*, 20(3), 45–50. <https://doi.org/10.1109/51.932724>
- Murat, F., Yildirim, O., Talo, M., Baloglu, U. B., Demir, Y., & Acharya, U. R. (2020). Application of deep learning techniques for heartbeats detection using ECG signals-analysis and review. *Computers in Biology and Medicine*, 120, 103726. <https://doi.org/10.1016/j.combiomed.2020.103726>
- Niroshana, S. M. I., Kuroda, S., Tanaka, K., & Chen, W. (2023). Beat-wise segmentation of electrocardiogram using adaptive windowing and deep neural network. *Scientific Reports*, 13(1), 11039. <https://doi.org/10.1038/s41598-023-37773-y>
- Potharaju, S., Raghavulu, K. V., Kumar, N. S. P., Salendra, S., Tambe, S. N., & Kantipudi, M. V. V. P. (2025). Multi-resolution hybrid sliding window approach for ECG arrhythmia detection using deep learning models. *Discover Applied Sciences*, 7(12), 1412. <https://doi.org/10.1007/s42452-025-07940-z>

- Sahoo, S., Dash, M., Behera, S., & Sabut, S. (2020). Machine learning approach to detect cardiac arrhythmias in ECG signals: A survey. *IRBM*, 41(4), 185–194. <https://doi.org/10.1016/j.irbm.2019.12.001>
- Shan, Z., Wang, Z., Yang, J., Zhou, D., & Liu, H. (2023). Extracting non-stationary signal under strong noise background: Time-varying system analysis. *Journal of Vibration and Control*, 29(17–18), 4036–4045. <https://doi.org/10.1177/10775463221109715>
- Siahaan, M., Panjaitan, S., Purba, A., Cahya, M., & Simarmata, A. (2026). Identifikasi aritmia pada lansia menggunakan algoritma K-Nearest Neighbor berdasarkan data elektrokardiogram. *Dinamik*, 31(1 SE-Articles). <https://doi.org/10.35315/dinamik.v31i1.10336>
- Song, M.-S., & Lee, S.-B. (2024). Comparative study of time-frequency transformation methods for ECG signal classification. *Frontiers in Signal Processing*, 4. <https://doi.org/10.3389/frsip.2024.1322334>
- V S., M., & R., T. (2024). A comprehensive survey of arrhythmia classification techniques. *Journal of Trends in Computer Science and Smart Technology*, 6(4), 357–373. <https://doi.org/10.36548/jtcsst.2024.4.003>
- Vásquez-Iturralde, F., Flores-Calero, M. J., Grijalva, F., & Rosales-Acosta, A. (2024). Automatic classification of cardiac arrhythmias using deep learning techniques: A systematic review. *IEEE Access*, 12, 118467–118492. <https://doi.org/10.1109/ACCESS.2024.3408282>