

Optimasi Deteksi Aritmia Pada Sinyal Ekg Menggunakan Pendekatan Divergence Kullback-Leiber

1st Muhammad Azlam Ikhlusal Fathir

S1 Teknik Biomedis

Telkom University

Bandung, Indonesia

muhammadazlam@student.telkomuniversity.ac.id

2nd Tito Waluyo Purboyo

Pembimbing I Teknik Biomedis

Telkom University

Bandung, Indonesia

titowaluyo@telkomuniversity.ac.id

3rd Annisa Humairani

Pembimbing II Teknik Biomedis

Telkom University

Bandung, Indonesia

annisahumairani@telkomuniversity.ac.id

Abstrak—Aritmia jantung merupakan gangguan irama jantung yang berpotensi memicu kondisi kardiovaskular serius apabila tidak terdeteksi secara dini. Kompleksitas morfologi sinyal elektrokardiogram (EKG), dimensi data yang tinggi, dan ketidakseimbangan distribusi kelas pada dataset menjadi tantangan dalam pengembangan sistem deteksi berbasis kecerdasan buatan. Penelitian ini bertujuan mengembangkan sistem klasifikasi aritmia berbasis sinyal EKG dari MIT-BIH Arrhythmia Database dengan menggabungkan *Discrete Wavelet Transform* (DWT) dan *Kullback–Leibler Divergence* (KL Divergence) untuk ekstraksi fitur. Data diseimbangkan menggunakan *random undersampling* sebelum ekstraksi, dengan empat pendekatan distribusi pada KL Divergence, yaitu *Uniform*, *Exponential*, *Gaussian*, dan *Combined*. klasifikasi dilakukan menggunakan *Support Vector Machine* (SVM) dengan *kernel RBF*, serta dievaluasi menggunakan metrik akurasi, *F1-score*, ROC AUC, *log loss*, *average precision* (AP), efisiensi komputasi, dan *Coefficient of Variation* (CV). Hasil menunjukkan bahwa *KL Combined* memberikan performa terbaik dengan akurasi 0,8895, *F1-score* 0,9039, AUC 0,9406, dan *log loss* uji 0,3012. *KL Combined* dinilai optimal untuk implementasi klinis karena menggabungkan akurasi tinggi, kestabilan, dan efisiensi, menjadikannya pilihan unggulan dalam sistem deteksi aritmia yang konsisten dan andal.

Kata kunci: Aritmia jantung, *Divergence Kullback-Leibler*, *Discrete Wavelet Transform*, EKG, MIT-BIH, *Support Vector Machine*

I. PENDAHULUAN

Penyakit kardiovaskular merupakan penyebab kematian tertinggi di dunia, dengan kontribusi hampir 32% dari total kematian global setiap tahunnya menurut *World Health Organization* (WHO) [1]. Salah satu bentuk gangguan kardiovaskular yang memerlukan perhatian khusus adalah aritmia jantung, yaitu ketidakaturan irama detak yang dapat berupa *takikardi*, *bradikardi*, maupun irama yang tidak teratur [2]. Kondisi ini disebabkan oleh disfungsi sistem kelistrikan jantung, dengan faktor risiko meliputi penyakit jantung, ketidakseimbangan elektrolit, stres, hingga efek samping obat-obatan tertentu [3]. Perkembangan teknologi elektrokardiogram (EKG) sejak penemuannya oleh *Willem Einthoven* telah membawa kemajuan besar dalam diagnosis aritmia [4], namun deteksi otomatis masih menghadapi tantangan signifikan akibat kemiripan morfologi antara sinyal normal dan abnormal [5], tingginya dimensi data, serta ketidakseimbangan distribusi kelas antara *beat* normal dan aritmia yang dapat menurunkan sensitivitas model terhadap *beat* aritmia [6].

Penelitian ini dikembangkan dari dua permasalahan utama, yaitu bagaimana mengembangkan algoritma deteksi aritmia yang mampu mengklasifikasikan denyut jantung normal dan aritmia pada dataset *MIT-BIH Arrhythmia Database* [18], serta bagaimana penerapan masing-masing pendekatan *Kullback–Leibler Divergence* (*Uniform*, *Exponential*, *Gaussian*, dan *Combined*) memengaruhi performa sistem dalam hal akurasi dan efisiensi [14][15]. Untuk menjawab permasalahan tersebut, diusulkan sistem deteksi aritmia berbasis *Discrete Wavelet Transform* (DWT) [24] dan *KL Divergence* yang dapat memisahkan komponen frekuensi dan waktu sinyal secara bertingkat [33], menangkap karakteristik morfologi kompleks gelombang QRS [26], serta menghitung perbedaan distribusi probabilistik antara sinyal aritmia dan referensi [27]. Dataset *MIT-BIH Arrhythmia Database* dengan *lead MLII* dan *V1* digunakan melalui tahapan *Preprocessing* yang mencakup *filtering* [11], normalisasi *Min-Max* [10], segmentasi berbasis *R-peak* [12], serta *random undersampling* untuk menyeimbangkan data [9]. Fitur hasil ekstraksi kemudian diklasifikasikan menggunakan *Support Vector Machine* (SVM) dengan *kernel RBF* [17], dan keempat metode *KL Divergence* dianalisis menggunakan *multiple metrics evaluation* [25] untuk menentukan pendekatan paling optimal dalam klasifikasi denyut aritmia. Pendekatan ini diharapkan mampu memberikan solusi yang akurat, stabil, dan efisien untuk mendukung implementasi klinis deteksi aritmia otomatis [28].

II. KAJIAN TEORI

Kajian teori pada penelitian ini membahas secara komprehensif landasan konseptual dan teknis yang digunakan dalam perancangan sistem deteksi aritmia berbasis sinyal EKG. Pembahasan diawali dengan penjelasan mengenai elektrokardiogram (EKG) dan aritmia jantung sebagai dasar pemahaman fenomena medis yang dianalisis, dilanjutkan dengan *MIT-BIH Arrhythmia Database* sebagai sumber data penelitian. Selanjutnya, diuraikan tahap *Preprocessing* untuk meningkatkan kualitas sinyal, diikuti metode penyeimbangan data (*balancing*) menggunakan *undersampling* guna mengatasi ketidakseimbangan kelas. Proses dilanjutkan pada tahap dekomposisi sinyal menggunakan *Discrete Wavelet Transform* (DWT), kemudian *Kullback–Leibler Divergence* (KL Divergence) digunakan sebagai metode ekstraksi fitur untuk membedakan distribusi probabilistik sinyal. Bagian akhir membahas tahap klasifikasi menggunakan *Support Vector Machine* dengan

kernel Radial Basis Function (RBF), yang dioptimalkan untuk menangani data berdimensi tinggi dan non-linear.

A. Elektrokardiogram dan Aritmia Jantung

Elektrokardiogram (EKG) merupakan metode non-invasif untuk merekam aktivitas listrik jantung melalui elektroda yang ditempatkan pada permukaan kulit, yang merepresentasikan proses depolarisasi dan repolarisasi dalam bentuk gelombang P, kompleks QRS, dan gelombang T [3]. Sinyal ini digunakan secara luas untuk mendeteksi kelainan irama jantung atau aritmia, yaitu kondisi di mana detak jantung menjadi terlalu cepat, terlalu lambat, atau tidak teratur akibat gangguan sistem kelistrikan jantung [1][2]. Perkembangan teknologi sejak penemuan EKG oleh *Willem Einthoven* telah menghasilkan perangkat dengan jumlah *lead* lebih banyak, digitalisasi sinyal, hingga sistem berbasis komputer untuk membantu analisis [19], termasuk penerapan *machine learning* untuk mendeteksi pola aritmia secara otomatis [20].

Rekaman EKG dapat dilakukan dengan konfigurasi *12-lead*, yang mencakup *lead* ekstremitas (I, II, III), *augmented* (aVR, aVL, aVF), dan *precordial* (V1–V6), masing-masing memberikan sudut pandang berbeda terhadap aktivitas listrik jantung [18][22]. Sinyal yang direkam memiliki amplitudo kecil, sekitar 0,5–5 mV, sehingga memerlukan penguatan dengan instrumentation amplifier yang memiliki *Common-Mode Rejection Ratio* (CMRR) tinggi untuk meminimalkan interferensi dari otot, peralatan medis, maupun jaringan listrik [24]. Setelah penguatan, sinyal difilter menggunakan *bandpass filter* (0,5–40 Hz) untuk mempertahankan komponen penting gelombang P, QRS, dan T sambil mereduksi *noise* seperti *baseline wander*, gangguan otot, dan interferensi AC [19].

Tahap selanjutnya adalah digitalisasi melalui *Analog-to-Digital Conversion* (ADC) dengan *sampling rate* umum 250–1000 Hz, di mana *database MIT-BIH* menggunakan 360 Hz untuk menjaga ketelitian representasi sinyal [22]. Komponen utama EKG memiliki makna klinis yang penting: gelombang P merefleksikan depolarisasi atrium [3], kompleks QRS menggambarkan depolarisasi ventrikel [4], gelombang T menunjukkan repolarisasi ventrikel [28], sementara interval PR dan QT memberikan informasi tentang waktu hantaran impuls dan total durasi aktivitas ventrikel [41]. Perubahan bentuk, durasi, atau interval dari komponen ini dapat menjadi indikator awal adanya kelainan ritme atau struktur jantung, sehingga pemahaman yang tepat terhadap karakteristik sinyal EKG menjadi landasan penting dalam deteksi aritmia [1].

B. Memuat Dataset MIT-BIH Arrhythmia Database

Penelitian ini menggunakan *MIT-BIH Arrhythmia Database*, salah satu dataset internasional yang paling banyak digunakan untuk pengembangan sistem deteksi aritmia berbasis sinyal EKG [22]. Dataset ini terdiri dari 48 rekaman berdurasi 30 menit, yang diambil dari pasien dengan berbagai jenis gangguan irama jantung dan telah dianotasi secara manual oleh ahli medis [26]. Setiap rekaman memiliki frekuensi sampling sebesar 360 Hz, sehingga morfologi gelombang seperti kompleks QRS, gelombang P, dan gelombang T dapat diidentifikasi secara presisi [22]. Penelitian ini memanfaatkan dua *lead* utama, yaitu *MLII* yang memberikan representasi irama jantung stabil, dan *VI* yang


lebih sensitif dalam mendeteksi aktivitas ventrikular dan abnormalitas lokal [26].

Setiap detak jantung dalam dataset diberi simbol satu huruf yang merepresentasikan jenis *beat*, berdasarkan pengamatan ahli kardiologi. Dalam penelitian ini, penentuan kategori *beat* mengacu pada standar *American Heart Association* (AHA) yang digunakan di *PhysioNet*, yang membagi simbol-simbol *beat* ke dalam enam kategori utama berdasarkan sumber aktivitas listrik, bentuk morfologi, dan relevansi klinisnya [18][40]. Beberapa contoh kategori meliputi kelas *Normal* (N, L, R), *Supraventricular* (A, a, J, S, e, j, x), *Ventricular* (V, E, !), *Fusion* (F, f), *Paced* (/), dan *Unknown* (Q). klasifikasi ini dipilih karena tidak hanya mempertimbangkan bentuk sinyal, tetapi juga konteks fisiologis dan klinis, sehingga meningkatkan akurasi deteksi [18].

Dalam implementasinya, penelitian ini menerapkan sistem pelabelan *biner*, di mana *beat* dengan kategori *Normal* diberi label 0 dan *beat* kategori lain (aritmia) diberi label 1. Label ini digunakan sebagai target pada tahap pelatihan model klasifikasi. Tahapan pengolahan data mengikuti rancangan sistem yang terdiri dari pemuatan data, *Preprocessing* (*filtering*, segmentasi, normalisasi), dekomposisi sinyal menggunakan *Discrete Wavelet Transform* (DWT), ekstraksi fitur berbasis *Kullback–Leibler Divergence* (KL Divergence), klasifikasi dengan *Support Vector Machine* (SVM) *kernel RBF*, evaluasi model, serta visualisasi hasil prediksi [22][26][40].

C. Rancangan sistem

Rancangan sistem deteksi aritmia yang diusulkan pada penelitian ini dirancang untuk memproses sinyal EKG dari *MIT-BIH Arrhythmia Database* melalui serangkaian tahapan yang saling terintegrasi.



GAMBAR 1

Framework sistem penelitian

Proses diawali dengan pemuatan data mentah yang kemudian masuk ke tahap *Preprocessing* berupa *filtering* untuk menghilangkan *noise* dan *baseline wander*, segmentasi berbasis puncak R (*R-peak*), serta normalisasi *Min–Max* guna menyamakan skala amplitudo antar *beat* [7][17]. Setelah itu, dilakukan penyeimbangan data (*balancing*) dengan metode *undersampling* untuk mengatasi ketidakseimbangan jumlah antara *beat* normal dan aritmia sehingga model dapat belajar secara proporsional [22][26]. Selanjutnya, sinyal yang telah diproses didekomposisi menggunakan *Discrete Wavelet Transform* (DWT) dengan basis *Daubechies 4* hingga level tertentu untuk memisahkan komponen frekuensi dan waktu, sehingga dapat menangkap detail morfologi gelombang PQRS secara optimal [24]. Fitur yang dihasilkan dari setiap level koefisien kemudian diekstraksi menggunakan metode *Kullback–Leibler Divergence* (KL Divergence) dalam empat

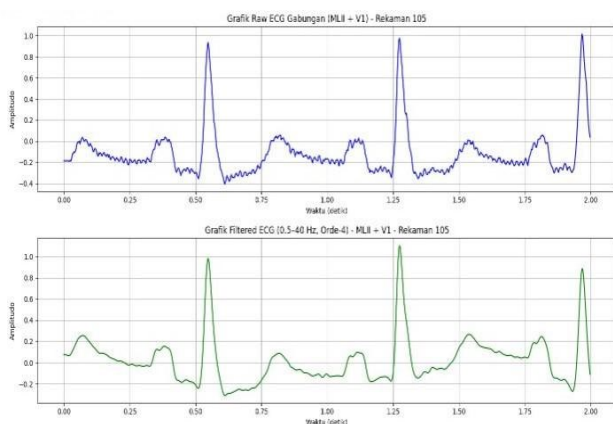
pendekatan distribusi referensi, yaitu *Uniform*, *Exponential*, *Gaussian*, dan *Combined*, guna mengukur perbedaan probabilistik antara *beat* aritmia dan referensi normal [29][36]. Hasil ekstraksi ini selanjutnya menjadi masukan bagi algoritma *Support Vector Machine* (SVM) dengan *kernel Radial Basis Function* (RBF) untuk klasifikasi *beat* menjadi kategori normal atau aritmia [41].

D. Tahap Preprocessing

Preprocessing merupakan langkah awal pengolahan sinyal EKG untuk meningkatkan kualitas dan mengurangi gangguan sebelum analisis lanjutan. Proses ini meliputi *filtering* untuk mereduksi *noise*, normalisasi untuk menyeragamkan skala amplitudo, segmentasi untuk memisahkan siklus jantung, dan penyeimbangan data agar model klasifikasi dapat belajar secara proporsional [22].

1) Filtering

Filtering merupakan tahap awal yang krusial dalam *Preprocessing* sinyal EKG untuk mempertahankan morfologi gelombang P, QRS, dan T, sekaligus mereduksi gangguan seperti *baseline wander*, *powerline interference*, dan *muscle noise* [12]. Meskipun dataset MIT-BIH Arrhythmia telah banyak digunakan secara klinis, sinyal tetap berpotensi mengandung *noise* akibat faktor fisiologis maupun teknis perekaman [6]. Penelitian ini menggunakan Butterworth bandpass filter orde-4 dengan rentang 0,5–40 Hz. Pemilihan rentang ini mempertahankan komponen utama gelombang P ($\pm 0,5$ –10 Hz), QRS (10–40 Hz), dan T (< 10 Hz), sekaligus menekan gangguan di luar spektrum tersebut [15][17]. Filter Butterworth dipilih karena respons frekuensinya halus tanpa *ripple* pada *passband* maupun *stopband* [11], dengan orde 4 yang dinilai optimal dalam memisahkan *noise* tanpa mengubah bentuk morfologi sinyal [19]. Dalam mencegah distorsi fase, digunakan metode *zero-phase filtering* dengan fungsi *filtfilt()* dari SciPy, yang memproses sinyal dua arah sehingga tidak terjadi *time shift* pada posisi PQRST [31]. Pendekatan ini penting karena pergeseran waktu sekecil apa pun dapat mengubah interpretasi diagnostik [17].



GAMBAR 2

perbandingan visual sinyal EKG sebelum dan sesudah *filtering* dengan Butterworth bandpass 0.5–40 Hz dan metode *zero-phase filtering*

Sebagai ilustrasi, Gambar 2, menampilkan perbandingan sinyal mentah gabungan MLII dan V1 sebelum dan sesudah *filtering*. Terlihat bahwa sinyal hasil penyaringan menjadi

lebih bersih, baseline stabil, amplitudo gelombang R lebih menonjol, dan komponen P serta T lebih jelas, sehingga meningkatkan efektivitas ekstraksi fitur pada tahap selanjutnya.

2) Min–Max Normalization

Normalisasi dilakukan untuk menyamakan skala amplitudo antar-*beat* dan antar-pasien, yang dapat bervariasi akibat perbedaan penempatan elektroda atau karakteristik alat perekam [21]. Metode yang digunakan adalah *Min–Max Normalization* per-*beat*, memetakan nilai minimum menjadi 0 dan maksimum menjadi 1 menggunakan persamaan:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Pendekatan ini mempertahankan bentuk relatif gelombang dan membantu mempercepat konvergensi model pembelajaran mesin seperti SVM, serta membuat klasifikasi lebih stabil terhadap variasi individu [20][21].

3) Segmentasi Beat

Segmentasi *beat* dilakukan untuk memotong sinyal EKG kontinu menjadi satu siklus detak jantung penuh, sehingga komponen penting seperti gelombang P, kompleks QRS, dan gelombang T dapat dianalisis secara akurat [20]. Penelitian ini menggunakan metode *fixed-window* sepanjang 256 sampel, terdiri dari ± 128 sampel sebelum dan sesudah puncak R (*R-peak*), dengan *sampling rate* 360 Hz atau setara $\pm 0,71$ detik per *beat*. Pemilihan *R-peak* sebagai pusat segmentasi didasarkan pada kestabilan dan dominasi titik ini dalam siklus jantung [21], sehingga morfologi P–QRS–T dapat terekam secara utuh.

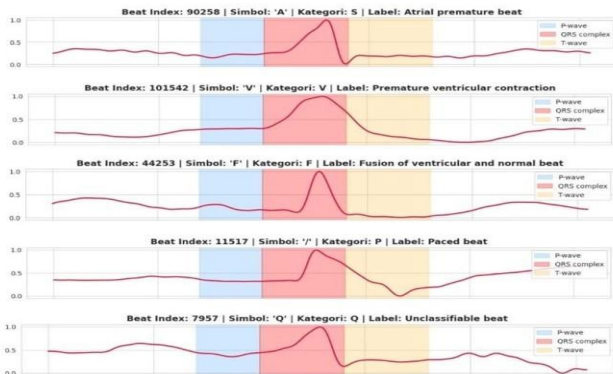
Label setiap *beat* ditentukan dengan mencocokkan segmen terhadap anotasi file *.atr* pada MIT-BIH Arrhythmia Database sesuai standar AHA PhysioNet, yang mengklasifikasikan *beat* menjadi enam kategori: Normal (N, L, R), Supraventrikular (S), Ventrikular (V), Fusi (F), Paced (P), dan *Unclassifiable* (Q) [18]. Untuk memudahkan klasifikasi, kategori ini dikonversi menjadi dua kelas *biner*, yaitu Kelas 0 untuk *beat* normal (N, L, R) dan Kelas 1 untuk *beat* aritmia (seluruh kategori lainnya). Simbol non-fungsional seperti “[”, “[”, dan “[” dikeskualikan karena hanya menandai ritme atau artefak teknis. Gambar 3 di bawah ini memperlihatkan contoh segmen *beat* normal, meliputi *normal beat*, *left bundle branch block*, dan *right bundle branch block*, yang tetap dikategorikan normal meskipun terdapat variasi morfologi [18].



GAMBAR 3

Contoh *beat* normal berdasarkan MIT-BIH Arrhythmia Database

Sementara itu, Gambar 4, berikut menunjukkan berbagai *beat* aritmia seperti *atrial premature beat*, *premature ventricular contraction*, *fusion beat*, *paced beat*, dan *unclassifiable beat*, yang ditandai dengan penyimpangan pada bentuk, durasi, atau keteraturan siklus [18].



GAMBAR 4


Contoh *beat* aritmia berdasarkan MIT-BIH Arrhythmia Database.

Proses segmentasi ini memastikan konsistensi data dan memudahkan model pembelajaran mesin membedakan antara *beat* normal dan aritmia secara efektif.

4) Penyeimbangan Data (Balancing)

Dalam pemrosesan dataset MIT-BIH Arrhythmia, ditemukan ketidakseimbangan yang signifikan antara jumlah *beat* jantung normal dan *beat* aritmia. Sebelum penyeimbangan, jumlah *beat* normal tercatat sebanyak 90.086, sedangkan *beat* aritmia hanya 15.616. Perbedaan proporsi yang besar ini berpotensi menimbulkan bias pada model klasifikasi, di mana model cenderung memprioritaskan prediksi terhadap kelas mayoritas (normal) dan mengabaikan kelas minoritas (aritmia) [10]. Dalam konteks sistem deteksi medis, bias seperti ini dapat mengurangi sensitivitas model terhadap deteksi pola aritmia, yang justru menjadi fokus utama dalam diagnosis dini penyakit jantung. Kondisi tersebut juga dapat menghasilkan metrik evaluasi yang menyesatkan, di mana akurasi tampak tinggi namun kemampuan deteksi aritmia rendah [18].

Untuk mengatasi ketimpangan ini, diterapkan *random undersampling* dengan rasio 1:1, yakni mengurangi jumlah sampel pada kelas mayoritas hingga setara dengan kelas minoritas. Setelah proses ini, kedua kelas memiliki jumlah *beat* yang sama, yaitu 15.616 untuk normal dan 15.616 untuk aritmia. Strategi ini membantu mengurangi dominasi kelas mayoritas, meningkatkan sensitivitas model terhadap aritmia, serta menghasilkan evaluasi yang lebih representatif terhadap performa sebenarnya.



GAMBAR 5

Distribusi *beat* normal dan aritmia sebelum dan sesudah *undersampling*.

Proses penyeimbangan ini dilakukan sebelum tahap utama, yaitu dekomposisi sinyal menggunakan *Discrete Wavelet Transform* (DWT) dan ekstraksi fitur berbasis *Kullback–Leibler Divergence* (KL Divergence). Dengan distribusi data yang seimbang, proses pembelajaran model berlangsung lebih adil, dan fitur yang dihasilkan dari DWT–KL Divergence memiliki kualitas yang lebih baik dalam membedakan antara *beat* normal dan aritmia [10][18].

E. Tahap Dekomposisi *Discrete Wavelet Transform* (DWT)

Sinyal elektrokardiogram (EKG) termasuk kategori sinyal non-stasioner, sehingga analisisnya memerlukan metode yang mampu merepresentasikan informasi secara simultan pada domain waktu dan frekuensi. *Discrete Wavelet Transform* (DWT) menjadi pilihan yang tepat karena mampu melakukan dekomposisi bertingkat untuk memisahkan komponen frekuensi rendah dan tinggi dengan resolusi adaptif [11]. Pada sinyal EKG, komponen frekuensi rendah biasanya memuat gelombang T dan baseline, sedangkan komponen frekuensi tinggi berkaitan dengan perubahan cepat seperti kompleks QRS [24].

DWT bekerja berdasarkan prinsip analisis multi-resolusi dengan menggunakan fungsi dasar *mother wavelet* yang mengalami dilasi (perubahan skala) dan translasi (pergeseran waktu). Prinsip ini memungkinkan deteksi pola global seperti gelombang T pada skala besar, sekaligus mengidentifikasi perubahan cepat seperti puncak QRS pada skala kecil [26]. Selain itu, DWT efektif dalam mereduksi *noise* umum seperti *baseline wander*, interferensi jaringan listrik, dan sinyal otot (EMG) [25].

Dalam penelitian ini, DWT diterapkan hingga *level* 4 dengan menggunakan *mother wavelet Daubechies-4* (db4) karena kemampuannya menyesuaikan morfologi kompleks QRS serta kestabilannya terhadap variasi karakteristik sinyal EKG [34]. Penerapan DWT ini memisahkan sinyal ke dalam domain waktu dan frekuensi secara simultan, sehingga setiap *level* dekomposisi memuat informasi fisiologis yang spesifik [11][26].

TABEL 1

Pembagian frekuensi DWT berdasarkan *sampling rate* 360Hz [24].

Level	Komponen	Rentang frekuensi (Hz)	Informasi yang terkandung
<i>cD1</i>	<i>Detail</i>	90 – 180	Noise frekuensi tinggi umumnya diabaikan
<i>cD2</i>	<i>Detail</i>	45 – 90	Komponen utama QRS kompleks (tajam, khas aritmia)
<i>cD3</i>	<i>Detail</i>	22.5 – 45	Detail kompleks QRS yang lebih halus
<i>cD4</i>	<i>Detail</i>	11.25 – 22.5	Gelombang P dan T
<i>cA4</i>	<i>Approx.</i>	< 11.25	Tren lambat dan komponen baseline.

Di antara komponen tersebut, *cD2* memiliki peran paling signifikan dalam membedakan detak jantung normal dan aritmia karena mencakup rentang frekuensi dominan kompleks QRS yang sering mengalami perubahan morfologi pada kondisi aritmia [26][34]. Informasi ini menjadi krusial dalam mendukung proses klasifikasi gangguan irama jantung, terutama ketika digunakan dalam ekstraksi fitur berbasis *Kullback–Leibler Divergence*, yang memanfaatkan distribusi statistik dari setiap *level* dekomposisi untuk membedakan detak normal dan aritmia [33].

F. *Kullback–Leibler Divergence* (*KL Divergence*) sebagai Ekstraksi Fitur

Setelah sinyal EKG didekomposisi menggunakan *Discrete Wavelet Transform* (DWT), tahap selanjutnya adalah ekstraksi fitur untuk merepresentasikan karakteristik morfologi sinyal dalam bentuk numerik. Penelitian ini menggunakan *Kullback–Leibler Divergence* (*KL Divergence*) untuk mengukur perbedaan antara distribusi probabilitas koefisien hasil dekomposisi yang bersifat empiris (*P*) dan distribusi referensi yang bersifat teoritis (*Q*) [14]. Pendekatan ini efektif untuk mengidentifikasi perubahan morfologi serta ketidakaturan gelombang yang menjadi indikator aritmia [30].

Distribusi empiris *P* dihitung berdasarkan histogram koefisien pada setiap *level* dekomposisi DWT, sedangkan distribusi referensi *Q* dibentuk dari model matematis berupa *Uniform*, *Exponential*, atau *gaussian* dengan parameter yang disesuaikan terhadap data aktual [15][16]. Pemilihan ketiga distribusi ini memberikan sudut pandang yang berbeda, yaitu penyimpangan dari kondisi acak, pola penurunan amplitudo fisiologis, dan kesesuaian terhadap bentuk distribusi normal. Untuk mencegah ketidakstabilan perhitungan akibat adanya probabilitas nol, digunakan teknik *ε-smoothing* dengan menambahkan nilai kecil $\varepsilon = 10^{-8}$ pada setiap probabilitas [14].

$$D_{KL}(P||Q) = \sum_{x=1}^n P(x) \cdot \log \left(\frac{P(x)}{Q(x)} \right) \quad (2)$$

dengan *P(x)* sebagai probabilitas aktual, *Q(x)* sebagai distribusi referensi, dan *n* jumlah *bin* pada histogram [26]. Nilai *KL Divergence* yang tinggi menunjukkan adanya perbedaan signifikan antara kedua distribusi, sedangkan nilai rendah menunjukkan kesamaan yang kuat.

TABEL 2

Interpretasi nilai *KL Divergence* dalam konteks sinyal EKG [14][16][32]

Kondisi Perbandingan <i>P(x)</i> dan <i>Q(x)</i>	Nilai <i>KL Divergence</i>	Interpretasi dalam Konteks Sinyal EKG
$P(x) = Q(x)$ (identik)	0	Beat kemungkinan besar normal; distribusi fitur serupa dengan referensi
<i>P(x)</i> sangat berbeda dari <i>Q(x)</i>	Tinggi	Beat kemungkinan aritmia; distribusi fitur sangat menyimpang dari pola normal
<i>P(x)</i> mirip tetapi tidak sama dengan <i>Q(x)</i>	Rendah	Beat cenderung normal; terdapat sedikit variasi dari distribusi referensi
Dibalik, $D_{KL}(Q P) \neq D_{KL}(P Q)$	Tidak sama	Hasil perhitungan berubah jika arah distribusi ditukar; penting untuk konsistensi evaluasi

Setelah interpretasi umum ini, pembahasan akan difokuskan pada dua pendekatan utama dalam perhitungan *KL Divergence*, yaitu metode individu dan metode gabungan. Keduanya akan dibandingkan dari berbagai aspek, meliputi jenis distribusi yang digunakan, sifat informasi yang dihasilkan, jumlah fitur, serta potensi kontribusi terhadap performa model klasifikasi. Dengan cara ini, perbedaan peran masing-masing pendekatan dapat dipahami secara lebih komprehensif sebelum hasilnya dianalisis pada tahap evaluasi.

1) *KL Divergence* Individual

Pendekatan ini menghitung *KL Divergence* untuk setiap jenis distribusi referensi secara terpisah, sehingga menghasilkan tiga kelompok nilai fitur yang berbeda.

1. Distribusi *Uniform* digunakan untuk menilai sejauh mana sinyal menyimpang dari pola acak atau tidak berpola, relevan dalam mendeteksi *baseline wander* maupun gangguan acak [14].
2. Distribusi *Exponential* digunakan untuk merepresentasikan pola penurunan amplitudo alami, misalnya pada fase repolarisasi ventrikel yang membentuk gelombang T [26].
3. Distribusi *Gaussian* digunakan untuk menilai kesesuaian bentuk sinyal dengan distribusi normal yang umum ditemukan pada data biologis, membantu

mengidentifikasi distorsi seperti kemiringan distribusi (*skewness*) atau keberadaan lebih dari satu puncak (*multimodalitas*) [15].

Ketiga nilai *KL Divergence* ini berfungsi sebagai indikator spesifik untuk mendeteksi berbagai bentuk ketidakaturan morfologi sinyal, baik yang bersifat acak, fisiologis, maupun struktural.

2) *KL Divergence Combined*

Pendekatan *Combined* dilakukan dengan menggabungkan seluruh fitur hasil *KL Divergence* dari distribusi *Uniform*, *Exponential*, dan *Gaussian* menjadi satu vektor fitur terpadu. Karena sinyal EKG didekomposisi menjadi lima komponen (cA4, cD4, cD3, cD2, cD1), jumlah total fitur yang dihasilkan adalah 15, yang berasal dari lima komponen dikalikan tiga jenis distribusi referensi [26].

Strategi penggabungan ini memungkinkan seluruh sudut pandang analisis tetap terwakili secara bersamaan, sehingga model klasifikasi memperoleh informasi yang lebih kaya dan beragam [32][34]. Beberapa penelitian melaporkan bahwa pendekatan ini cenderung menghasilkan akurasi dan kestabilan klasifikasi yang lebih baik dibandingkan metode individual, terutama pada sinyal EKG yang kompleks dan mengandung berbagai gangguan [32].

G. Tahap Klasifikasi: *Support Vector Machine* dengan *Kernel RBF*

Tahap klasifikasi pada penelitian ini menggunakan *Support Vector Machine* (SVM) dengan *kernel Radial Basis Function* (RBF). Algoritma ini dipilih karena kemampuannya menangani data berdimensi tinggi dengan pola non-linear, sesuai karakteristik sinyal Elektrokardiogram (EKG) yang bersifat non-stasioner dan memiliki variasi morfologi antar individu maupun antar waktu, khususnya pada kondisi aritmia seperti *Premature Ventricular Contraction* (PVC) dan *atrial fibrillation* [17][29]. Prinsip dasar SVM adalah membentuk *hyperplane* yang memisahkan dua kelas dengan margin maksimum. Pada kasus data non-linear, *kernel RBF* memetakan data ke ruang fitur berdimensi lebih tinggi agar pemisahan dapat dilakukan secara efektif. Secara matematis, *kernel RBF* dirumuskan sebagai:

$$K(x, x') = \exp(-\gamma ||x - x'||^2) \quad (3)$$

Fungsi ini mengukur kesamaan antar titik data berdasarkan jarak Euclidean, sehingga pola non-linear dapat dipisahkan secara optimal [30]. Pendekatan ini sangat relevan terhadap fitur yang dihasilkan dari *Kullback-Leibler Divergence* (*KL Divergence*), yang distribusinya sering kali kompleks.

1) Parameter Model dan *Bias-Variance Trade-off*

Parameter C mengatur toleransi terhadap kesalahan klasifikasi. Nilai yang terlalu besar cenderung menyebabkan *overfitting*, sedangkan nilai yang terlalu kecil berpotensi menyebabkan *underfitting*. Pada penelitian ini digunakan $C = 1.0$ untuk menjaga keseimbangan antara lebar margin dan tingkat kesalahan yang wajar. *Parameter γ* diatur dengan skema *scale*:

$$\gamma = \frac{1}{n_{features} \cdot Var(X)}, C = 1.0, \gamma = scale \quad (4)$$

Pengaturan ini membuat γ beradaptasi terhadap jumlah fitur dan varians data, menghasilkan bias rendah dan *varians*

sedang. Secara teoretis, hubungan *bias-variance* dapat dirumuskan sebagai:

$$Err(x) = Bias(x)^2 + Var(x) + \sigma \quad (5)$$

Pendekatan ini memastikan model cukup fleksibel untuk menangkap pola kompleks namun tetap stabil terhadap variasi data [29][32].

2) Kompleksitas Model dan Margin

Evaluasi kompleksitas dilakukan dengan melihat jumlah *support vector*:

$$SV_{total} = |support_| \quad (6)$$

$$SV_{class0} = \sum_{i \in SV} [y_i = 0], SV_{class1} = \sum_{i \in SV} [y_i = 1] \quad (7)$$

Kelas dengan jumlah *support vector* lebih banyak biasanya lebih sulit dipisahkan. Estimasi margin teoritis adalah:

$$\frac{1}{||\omega||} \quad (8)$$

Karena pada SVM-RBF nilai ω tidak dihitung secara eksplisit, digunakan pendekatan:

$$Margin_{est} = \frac{1}{\sqrt{\sum_i (dual_coef_i^2)}} \quad (9)$$

Selain itu, waktu pelatihan dan prediksi dicatat dalam milidetik untuk mengukur efisiensi algoritma [32].

3) Kompleksitas Teoretis dan Implementasi

Berdasarkan literatur, metode *KL Divergence Uniform* memiliki kompleksitas terendah karena tidak memerlukan estimasi parameter [14][26]. *Exponential* sedikit lebih kompleks karena memerlukan fungsi eksponensial [25], sedangkan *Gaussian* paling kompleks karena membutuhkan estimasi *mean*, *varians*, dan operasi eksponensial-logaritmik [34]. Pendekatan *Combined* memiliki kompleksitas tertinggi karena menggabungkan ketiganya, yang secara teoritis dapat meningkatkan waktu proses hingga 2–3 kali lipat. Namun, hasil aktual dapat berbeda tergantung optimasi kode, penggunaan komputasi tervektorisasi (*array programming*), dan *backend BLAS/LAPACK* yang memproses operasi matriks secara efisien [41][42]. Faktor ini memungkinkan perbedaan signifikan antara estimasi teoritis dan waktu eksekusi di lapangan.

4) Integrasi dalam *Pipeline* Penelitian

Sebelum klasifikasi, dataset diseimbangkan menggunakan *random undersampling* dengan rasio 1:1, kemudian dibagi menggunakan *stratified train-test split* 80:20 untuk menjaga proporsi kelas [6][31]. Konfigurasi SVM-RBF, evaluasi kompleksitas, serta kalibrasi probabilitas menjadi fondasi dalam analisis hasil yang dibahas pada Bab 4, sehingga keterkaitan antara desain model dan performa dapat dipahami secara menyeluruh.

H. Penghitungan *Feature Importance* Berdasarkan Ekstraksi *KL Divergence*

Setelah sinyal EKG melalui *Discrete Wavelet Transform* (DWT) hingga beberapa *level* dekomposisi, nilai *Kullback-Leibler Divergence* (*KL Divergence*) dihitung untuk setiap *level* menggunakan tiga distribusi referensi:

Uniform, *Exponential*, dan *gaussian* [14]. Nilai *KL Divergence* diperoleh dari perbandingan distribusi aktual koefisien sinyal (P) dengan distribusi referensi (Q) masing-masing [35].

Hasil perhitungan dari tiap distribusi membentuk vektor fitur yang kemudian diuji kontribusinya terhadap klasifikasi *beat* normal dan aritmia menggunakan *Support Vector Machine – Radial Basis Function* (SVM-RBF) [6]. Penilaian dilakukan melalui *permutation importance*, yaitu mengukur penurunan akurasi model saat suatu fitur diacak. Semakin besar penurunannya, semakin tinggi nilai *importance*-nya [37].

Selain evaluasi per distribusi, penelitian ini menerapkan pendekatan *KL Combined*, yaitu menggabungkan seluruh fitur dari ketiga distribusi menjadi satu himpunan berisi 15 fitur ($5 \text{ level} \times 3 \text{ distribusi}$) [14]. Proses penggabungan dilakukan tanpa mengubah distribusi referensi, sehingga setiap keluaran *KL Divergence* tetap merepresentasikan karakteristik asli Q masing-masing. Integrasi ini memungkinkan interaksi non-linear dan saling melengkapi antarfitur dari distribusi berbeda, sehingga fitur yang semula kurang dominan dapat menjadi relevan, sedangkan fitur redundan cenderung menurun kontribusinya [39]. Pendekatan *KL Combined* diharapkan mampu menangkap variasi morfologi sinyal EKG secara lebih komprehensif, sekaligus meningkatkan akurasi dan stabilitas model klasifikasi.

I. Kerangka *Multiple Metrics Evaluation*

Penilaian performa sistem deteksi aritmia dilakukan menggunakan kerangka *multiple metrics evaluation* untuk memastikan kinerja model tidak bergantung pada satu indikator saja, melainkan mencakup aspek akurasi, sensitivitas, kualitas probabilistik, efisiensi, dan stabilitas model [14][29]. Pendekatan ini penting dalam konteks aplikasi medis berbasis sinyal EKG yang menuntut ketelitian tinggi.

1) Akurasi (*Accuracy*)

Mengukur proporsi prediksi benar terhadap seluruh data, dihitung dengan:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.16)$$

di mana *TP* adalah aritmia terdeteksi benar, *TN* normal dikenali benar, *FP* normal salah terdeteksi sebagai aritmia, dan *FN* aritmia tidak terdeteksi [14].

2) *Precision*, *Recall*, *F1-Score*, *Specificity*, dan *FPR*

- *Precision*: ketepatan prediksi aritmia terhadap total deteksi aritmia.

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

- *Recall / Sensitivity* (TPR): mengukur seberapa banyak kasus aritmia yang berhasil terdeteksi.

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

- *F1-Score*: rata-rata harmonik dari *precision* dan *recall*, yang sesuai untuk kondisi data yang tidak seimbang.

$$F1 \text{ Score} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (13)$$

- *Specificity*: Metrik ini mengukur kemampuan model dalam mengenali *beat* normal secara benar.

$$Specificity = \frac{TN}{TN + FP} \quad (14)$$

- False Positive Rate (FPR): merupakan kebalikan dari *specificity*

$$FPR = \frac{FP}{FP + TN} \quad (15)$$

3) Evaluasi Probabilistik

Kualitas probabilitas prediksi dinilai dengan *Average Precision* (AP) yang merepresentasikan area rata-rata di bawah kurva *Precision–Recall*, serta *Receiver Operating Characteristic* (ROC) yang memplot *TPR* terhadap *FPR*. Nilai *Area Under Curve* (AUC) yang mendekati 1 menunjukkan kemampuan diskriminasi kelas yang baik [14].

4) Logarithmic Loss (Log loss)

Mengukur seberapa tepat prediksi probabilistik model, dengan. Dalam penelitian ini, *log loss* dihitung pada dua jenis data:

- *Log loss Train* mengukur tingkat keyakinan model terhadap data pelatihan.
- *Log loss Test* mengevaluasi kualitas prediksi pada data pengujian, dan menjadi indikator utama dalam menilai akurasi probabilistik model.

Dengan rumus:

$$Log \text{ Loss} = -\frac{1}{N} = 1 \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (16)$$

di mana y_i adalah label sebenarnya, p_i probabilitas prediksi, dan N jumlah data [37]. Perhitungan dilakukan untuk data pelatihan (*Log loss Train*) dan pengujian (*Log loss Test*) sebagai indikator generalisasi model.

5) Efisiensi Model

Efisiensi dihitung dengan membandingkan performa terhadap jumlah fitur:

- *Log loss Efficiency*: Metrik ini mengukur efisiensi model dalam menghasilkan prediksi probabilistik terhadap jumlah fitur yang digunakan.

$$LL \text{ Efficiency} = \frac{1}{Log \text{ Loss}_{Test} \times \text{Jumlah fitur}} \quad (17)$$

- Metrik ini menghitung efektivitas model dalam memisahkan kelas berdasarkan rasio nilai AUC terhadap jumlah fitur

$$ROC \text{ AUC Efficiency} = \frac{ROC \text{ AUC Score}}{\text{Jumlah Fitur}} \quad (18)$$

Nilai lebih tinggi menunjukkan kinerja optimal dengan kompleksitas minimal [39].

6) *Overfitting Indicator*

Mengukur selisih antara *log loss* pelatihan dan pengujian:

$$Overfitting = |Log Loss_{Train} - Log Loss_{Test}| \quad (19)$$

Nilai kecil menunjukkan generalisasi yang baik [36].

7) Stabilitas Model – Coefficient of Variation (CV%)

Metrik ini digunakan untuk menilai kemampuan model selama proses *cross-validation*. Semakin kecil nilai CV, semakin stabil dan andal performa model.

• Cross-Validation

Merupakan metode evaluasi model yang membagi dataset menjadi beberapa bagian (*fold*). Untuk *5-fold cross-validation*, dataset dibagi menjadi 5 bagian. Pada setiap iterasi, 4 *fold* digunakan untuk pelatihan dan 1 *fold* untuk pengujian. Proses ini diulang 5 kali, memastikan setiap *fold* pernah menjadi data pengujian. Akurasi dihitung pada setiap iterasi, kemudian kelima hasilnya dirata-ratakan untuk mendapatkan evaluasi model yang lebih konsisten dan stabil.

$$Fold Size = \frac{Jumlah\ Sampel}{k} \quad (20)$$

• Mean Accuracy (μ)

Merupakan rata-rata nilai akurasi yang diperoleh dari seluruh fold pada proses *cross-validation*. jika Acc_i adalah akurasi pada fold ke- i , maka:

$$\mu = \frac{\sum_{i=1}^k Acc_i}{k} \quad (21)$$

• Standard Deviasi (σ)

Simpangan baku mengukur seberapa besar penyebaran nilai akurasi antar fold dari nilai rata-rata. Semakin kecil σ , semakin konsisten performa model di setiap *fold*. Rumus:

$$\sigma = \sqrt{\frac{\sum_{i=1}^k (Acc_i - \mu)^2}{k}} \quad (22)$$

• Coefficient of Variation (CV%)

Coefficient of Variation adalah ukuran stabilitas relatif yang dinyatakan dalam persen (%). CV membandingkan besarnya penyebaran (σ) terhadap rata-rata (μ):

$$CV \% = \frac{\sigma}{\mu} \times 100\% \quad (23)$$

Nilai $CV < 1\%$ menunjukkan performa yang sangat stabil dalam aplikasi medis [29][39]

III. HASIL PENELITIAN

Memberikan gambaran rancangan penelitian yang meliputi prosedur atau langkah-langkah penelitian, waktu penelitian, sumber data, cara perolehan data dan menjelaskan metode yang akan digunakan dalam penelitian [10 pts].

A. Evaluasi Feature Importance Berdasarkan Metode KL Divergence

Definisikan Bagian ini memaparkan evaluasi kontribusi fitur hasil ekstraksi sinyal EKG menggunakan *Kullback-Leibler Divergence* (KL Divergence) setelah dekomposisi sinyal dengan *Discrete Wavelet Transform* (DWT) hingga level 4. Analisis dilakukan pada tiga

pendekatan distribusi individu (*Uniform*, *Exponential*, dan *Gaussian*) serta pendekatan gabungan (*KL Combined*). Evaluasi ini bertujuan mengidentifikasi fitur paling berpengaruh dalam membedakan detak jantung normal dan aritmia, serta membandingkan efektivitas antar metode berdasarkan perubahan peringkat (*ranking*) fitur.

1) Analisis Feature Importance – Metode Individu

Pendekatan individu mengevaluasi kontribusi fitur dari masing-masing distribusi referensi *KL Divergence* secara terpisah. Setiap distribusi menghasilkan lima fitur dari level DWT yang berbeda.

Rank	KL Uniform	Imp	KL Exponential	Imp	KL Gaussian	Imp
1	dwt2_kl_uniform	0.1470	dwt1_kl_exponential	0.0994	dwt2_kl_gaussian	0.1191
2	dwt4_kl_uniform	0.0759	dwt4_kl_exponential	0.0881	dwt5_kl_gaussian	0.0628
3	dwt5_kl_uniform	0.0552	dwt3_kl_exponential	0.0827	dwt4_kl_gaussian	0.0618
4	dwt3_kl_uniform	0.0384	dwt5_kl_exponential	0.0668	dwt3_kl_gaussian	0.0258
5	dwt1_kl_uniform	0.0211	dwt2_kl_exponential	0.0433	dwt1_kl_gaussian	0.0167

GAMBAR 6

Feature Importance dari Pendekatan KL Divergence (Metode Individu)

Pada pendekatan *KL Uniform*, fitur dengan kontribusi tertinggi berasal dari level DWT-2 dengan nilai *importance* sebesar 0,1470, diikuti oleh DWT-4 (0,0759) dan DWT-5 (0,0552), sedangkan DWT-3 dan DWT-1 menempati posisi keempat dan kelima. Level DWT-2 berkorespondensi dengan rentang frekuensi 45–90 Hz, yang menurut (tabel 3.2) merupakan wilayah dominan kompleks QRS yang tajam dan sering menjadi indikator utama aritmia ventrikular. Dominasi pada level ini menegaskan bahwa *KL Uniform* efektif menyortir informasi terkait aktivitas listrik ventrikel, terutama pada sinyal dengan pola QRS yang *abnormal* [26]. Urutan peringkat yang jelas juga menunjukkan bahwa metode ini lebih selektif pada level tertentu dibandingkan menyebar ke seluruh level DWT.

Pendekatan *KL Exponential* menampilkan distribusi kontribusi fitur yang lebih merata dibandingkan *KL Uniform*. Fitur dengan nilai tertinggi berasal dari DWT-1 (0,0994), diikuti oleh DWT-4 (0,0881) dan DWT-3 (0,0827), sedangkan DWT-5 dan DWT-2 menempati peringkat keempat dan kelima. Level DWT-1 berada pada rentang 90 hingga 180 Hz yang umumnya dikaitkan dengan komponen frekuensi tinggi, mencakup *noise* maupun transien tajam. Meskipun demikian, pada kasus aritmia rentang ini juga dapat memuat detail perubahan cepat pada kompleks QRS. Level DWT-3 dengan rentang 22,5 hingga 45 Hz serta DWT-4 dengan rentang 11,25 hingga 22,5 Hz yang turut dominan mengindikasikan bahwa *KL Exponential* mampu menangkap pola transien pada gelombang QRS dan T yang *abnormal* [34]. Hal ini menunjukkan bahwa metode ini cenderung lebih adaptif terhadap perubahan bentuk gelombang yang tidak menetap pada satu frekuensi tertentu.

Pada pendekatan *KL Gaussian*, fitur dengan kontribusi terbesar kembali berasal dari DWT-2 (0,1191), diikuti oleh DWT-5 (0,0628) dan DWT-4 (0,0618), dengan DWT-3 dan DWT-1 di posisi berikutnya. Level DWT-5 (*approximation*) mencakup frekuensi <11,25 Hz yang berhubungan dengan gelombang P, T, dan *baseline trend*. Meskipun urutan level mirip dengan *KL Uniform*, nilai keseluruhan lebih rendah, menunjukkan bahwa *KL Gaussian* lebih peka terhadap variasi fisiologis normal (misalnya variasi gelombang P/T) dibandingkan mendeteksi pola QRS

yang ekstrem. Hal ini menjadikan *KL Gaussian* lebih stabil pada sinyal normal, namun kurang tajam untuk pola khas aritmia [26].

Secara umum, metode individu memberikan informasi spesifik keunggulan masing-masing distribusi, tetapi kurang mampu mengintegrasikan kekuatan fitur dari berbagai spektrum frekuensi secara bersamaan.

2) Analisis Feature Importance – Metode Combined

Pendekatan *Combined* mengintegrasikan seluruh fitur dari ketiga distribusi referensi *KL Divergence (Uniform, Exponential, Gaussian)* pada lima level DWT, menghasilkan total 15 fitur yang dianalisis secara simultan [34].

Rank	Feature	Importance
1	dwt2_kl_uniform	0.3163
2	dwt2_kl_exponential	0.1278
3	dwt5_kl_exponential	0.1268
4	dwt3_kl_uniform	0.0901
5	dwt5_kl_gaussian	0.0765
6	dwt4_kl_exponential	0.0762
7	dwt1_kl_exponential	0.0718
8	dwt1_kl_gaussian	0.0684
9	dwt3_kl_exponential	0.0572
10	dwt1_kl_uniform	0.0549
11	dwt3_kl_gaussian	0.0440
12	dwt4_kl_uniform	0.0402
13	dwt2_kl_gaussian	0.0319
14	dwt5_kl_uniform	0.0319
15	dwt4_kl_gaussian	0.0262

GAMBAR 7

Feature Importance dari Pendekatan *KL Divergence* (Metode *Combined*)

Pendekatan *KL Combined* mengintegrasikan seluruh fitur dari distribusi referensi *Uniform, Exponential*, dan *gaussian* menjadi satu himpunan berisi 15 fitur yang dievaluasi secara global. Integrasi ini bertujuan memanfaatkan keunggulan masing-masing distribusi untuk menghasilkan representasi fitur yang lebih kaya dan seimbang dalam mendukung klasifikasi detak normal dan aritmia [34].

Berdasarkan hasil perhitungan, fitur *dwt2_KL Uniform* menempati peringkat tertinggi dengan nilai *importance* sebesar 0,3163, jauh melebihi fitur lainnya. *Level DWT-2* (45–90 Hz) diketahui merupakan rentang frekuensi yang mendominasi morfologi kompleks QRS, sehingga tingginya nilai pada fitur ini konsisten dengan temuan metode individual yang menegaskan peran pentingnya dalam membedakan detak normal dan aritmia ventrikular [34][36].

Di posisi berikutnya, *dwt2_KL Exponential* (0,1278) dan *dwt5_KL Exponential* (0,1268) menunjukkan kontribusi tinggi dari metode *Exponential*. *Level DWT-5* (<11,25 Hz) merepresentasikan tren lambat, termasuk komponen *baseline* dan gelombang T, yang relevan untuk mendeteksi perubahan repolarisasi pada beberapa jenis aritmia. Kombinasi *level 2* dan *level 5* ini memperlihatkan bahwa metode *Exponential* tetap mempertahankan pengaruhnya dalam pendekatan gabungan, meskipun hanya sebagian fiturnya yang berada pada peringkat atas.

Fitur *dwt3_KL Uniform* (0,0901) yang pada metode individual tidak selalu dominan, mengalami kenaikan signifikan dalam pendekatan gabungan. *Level DWT-3* (22,5–45 Hz) mengandung detail kompleks QRS yang lebih halus, sehingga posisinya yang tinggi mengindikasikan bahwa

sinergi antar distribusi mampu meningkatkan relevansi informasi detail ini. Sementara itu, *dwt5_KL gaussian* (0,0765) menjadi salah satu perwakilan *gaussian* dengan kontribusi terbesar. Hal ini menandakan bahwa meskipun *gaussian* cenderung stabil pada data normal, kontribusinya tetap signifikan dalam melengkapi informasi frekuensi rendah untuk klasifikasi gabungan [38].

Pola peringkat ini juga memperlihatkan bahwa fitur yang sebelumnya kurang menonjol, seperti *dwt1_KL gaussian* (0,0684) dan *dwt1_KL Exponential* (0,0718), tetap memberikan kontribusi yang berarti dalam pendekatan gabungan. *Level DWT-1* (90–180 Hz) umumnya berkaitan dengan *noise* atau transien tajam, namun pada sinyal aritmia rentang ini dapat memuat perubahan cepat pada morfologi QRS. Keberadaan fitur-fitur tersebut pada posisi menengah menunjukkan perannya yang penting sebagai pelengkap informasi dari *level* frekuensi yang lebih rendah [34].

Fenomena pergeseran posisi ini merupakan konsekuensi wajar dari integrasi ketiga metode individual dalam sistem klasifikasi berbasis *machine learning*. Perubahan peringkat fitur pada *KL Combined* dipengaruhi oleh beberapa faktor utama, antara lain:

- **Interaksi antar fitur:** Model SVM dengan *kernel RBF* memproses semua fitur secara simultan sehingga hubungan antar fitur saling memengaruhi. Fitur yang sebelumnya kurang dominan dapat menjadi signifikan ketika memperkuat kontribusi fitur lain, seperti *dwt3_KL Uniform* dan *dwt1_KL gaussian* yang naik peringkat [36].
- **Redundansi dan komplementaritas:** Fitur dengan informasi yang tumpang tindih akan cenderung berkurang kontribusinya, sedangkan fitur yang melengkapi informasi distribusi lain akan meningkat peringkatnya. Contohnya, *dwt5_KL gaussian* dan *dwt1_KL Exponential* berperan melengkapi informasi yang tidak sepenuhnya diwakili oleh distribusi *Uniform*.
- **Curse of dimensionality:** Dengan 15 fitur, ruang fitur menjadi lebih kompleks sehingga hanya kombinasi tertentu yang relevan dalam membentuk *decision boundary*. Hal ini menyebabkan fitur dominan di metode individu tidak selalu mempertahankan posisinya di pendekatan gabungan [38].
- **Perbedaan ruang solusi:** Pada metode individu, penilaian dilakukan terhadap lima kandidat fitur, sedangkan *KL Combined* mengevaluasi seluruh 15 fitur sekaligus, membuat seleksi menjadi lebih kompetitif dan stabil [36].

Dengan demikian, perubahan peringkat dalam *KL Combined* bukanlah kelemahan, melainkan representasi dari interaksi non-linear antar fitur dalam ruang berdimensi tinggi. Pendekatan ini tidak hanya mempertahankan kekuatan fitur dominan, tetapi juga mengangkat kontribusi fitur pendukung yang sebelumnya kurang menonjol, sehingga mampu meningkatkan akurasi serta memperkaya representasi morfologi sinyal EKG [34][38].

B. Evaluasi Multiple Matrices Evaluation Berdasarkan Metode KL Divergence

Bab ini menyajikan evaluasi performa sistem deteksi aritmia berdasarkan berbagai metrik *KL* klasifikasi. Empat pendekatan distribusi *KL Divergence* yang diuji meliputi *KL Uniform*, *KL Exponential*, *KL Gaussian*, dan *KL*

Combined, dengan model *KL*asifikasi *Support Vector Machine* (SVM) berbasis *kernel* RBF. Evaluasi dilakukan secara komprehensif melalui pengukuran *confusion matrix*, akurasi, metrik probabilitas (AP dan AUC), *log loss*, efisiensi, serta stabilitas model (CV). Tujuannya adalah untuk mengidentifikasi pendekatan yang paling efektif dan andal dalam membedakan detak jantung normal dan aritmia. Uraian hasil disajikan secara sistematis dalam subbab berikut.

1) Hasil dan Analisis Penghitungan *Confusion Matrix*

Pada tahap ini dilakukan evaluasi terhadap performa sistem klasifikasi *biner* dalam membedakan antara detak jantung normal dan aritmia berdasarkan keluaran *confusion matrix*. Setiap pendekatan *KL Divergence* menghasilkan nilai *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) yang menggambarkan keberhasilan dan kesalahan sistem dalam melakukan prediksi kelas. Hasil penghitungan *confusion matrix* untuk keempat pendekatan disajikan pada tabel berikut:

TABEL 3
Binary Confusion Matrix Result

Method	TP	TN	FP	FN
<i>Uniform</i>	3033	1663	920	631
<i>Exponential</i>	2900	1843	740	764
<i>Gaussian</i>	3081	1518	1065	583
<i>Combined</i>	3244	2313	270	420

Hasil menunjukkan *KL Combined* menjadi metode terbaik. Nilai *True Positive* (TP) sebesar 3244 dan *False Negative* (FN) terendah 420 menunjukkan sensitivitas sangat tinggi, sehingga detak jantung aritmia terdeteksi dengan baik. Nilai *True Negative* (TN) terbesar 2313 dan *False Positive* (FP) terendah 270 juga mencerminkan spesifisitas tinggi, yang berarti risiko *false alarm* sangat rendah. Kombinasi ini menjadikan *KL Combined* unggul baik dalam mendeteksi aritmia maupun memastikan detak normal tidak salah *KL*asifikasi [36].

Di posisi kedua, *KL Uniform* mencatat TP sebesar 3033 dan FN sebesar 631, yang menunjukkan sensitivitas menengah dan relatif lebih baik dibanding *KL Exponential*. TN-nya (1663) memang lebih rendah, sedangkan FP-nya (920) lebih tinggi dibanding *KL Exponential*, sehingga spesifisitasnya sedikit lebih rendah. Namun, jumlah FN yang lebih kecil membuat metode ini lebih aman dalam mendeteksi aritmia, sesuai dengan prioritas medis yang mengutamakan minimisasi *missed detection* [34][36].

Peringkat ketiga ditempati *KL Exponential*, yang memiliki TN cukup tinggi (1843) dan FP rendah (740), menunjukkan spesifisitas yang baik. Akan tetapi, sensitivitasnya terendah (TP 2900, FN tertinggi 764) sehingga lebih sering gagal mendeteksi aritmia dibanding metode lain. Meski demikian, pada aplikasi yang lebih menekankan pengurangan *false alarm*, metode ini tetap memiliki relevansi [34][36].

Terakhir, *KL Gaussian* memiliki TP cukup tinggi (3081) dan FN relatif rendah (583), tetapi TN terendah (1518) dan FP tertinggi (1065) di antara semua metode. Kondisi ini mengindikasikan spesifisitas yang buruk, sehingga model sering salah mengklasifikasikan detak aritmia sebagai

normal, berpotensi memicu *false alarm* berlebihan dan mengurangi efisiensi pemantauan medis [38].

Secara umum, TP yang besar menunjukkan kemampuan model dalam mendeteksi aritmia dengan benar (*high sensitivity*), sedangkan FN yang besar menandakan banyaknya kasus aritmia yang terlewat (*missed detection*). TN yang besar menunjukkan kemampuan mengenali detak normal dengan benar (*high specificity*), sedangkan FP yang besar berarti banyak detak normal yang salah diklasifikasikan sebagai aritmia (*false alarm*). Urutan performa ini menegaskan bahwa integrasi fitur lintas distribusi pada *KL Combined* tidak hanya mempertahankan sensitivitas tinggi, tetapi juga meningkatkan spesifisitas, menjadikannya metode paling andal untuk deteksi aritmia berbasis EKG [34][36][38].

2) Hasil dan Analisis *Metrik Evaluasi* klasifikasi

Setelah diperoleh hasil *confusion matrix*, dilakukan perhitungan enam metrik evaluasi: accuracy, specificity, false positive rate (FPR), precision, recall, dan F1-score. Fokus penilaian mengikuti prioritas medis, dengan *recall* sebagai indikator utama untuk meminimalkan *missed detection*, diikuti F1-score, precision, specificity, FPR, dan terakhir accuracy [36].

Method	Accuracy	Specificity	FPR	Precision	Recall	F1-Score
KL Uniform	0.7517	0.6438	0.3562	0.7673	0.8278	0.7964
KL Exponential	0.7592	0.7135	0.2865	0.7967	0.7915	0.7941
KL Gaussian	0.7362	0.5877	0.4123	0.7431	0.8409	0.7890
KL Combined	0.8895	0.8955	0.1045	0.9232	0.8854	0.9039

GAMBAR 8
Evaluasi Kinerja SVM-RBF

Hasil menunjukkan *KL Combined* unggul di seluruh aspek, dengan *recall* 0,8854 dan F1-score tertinggi 0,9039, menandakan keseimbangan optimal antara sensitivitas dan ketepatan *KL*asifikasi [34]. Precision tertinggi (0,9232) mengindikasikan minimnya *false positive*, sementara specificity 0,8955 dan FPR terendah 0,1045 memastikan *false alarm* sangat rendah. Accuracy yang mencapai 0,8895 menegaskan konsistensi kinerjanya [38].

KL Uniform menjadi metode individu terbaik dengan *recall* 0,8278 dan F1-score 0,7964. Meskipun specificity rendah (0,6438) dan FPR cukup tinggi (0,3562), metode ini lebih aman secara klinis karena tidak mengorbankan banyak deteksi aritmia demi menekan *false alarm* [36].

KL Exponential memiliki specificity 0,7135 dan FPR 0,2865 yang lebih baik daripada *KL Uniform*, tetapi *recall* terendah 0,7915 membuatnya kurang efektif dalam deteksi aritmia. Meski begitu, F1-score 0,7951 dan precision 0,7967 cukup stabil, sehingga relevan untuk aplikasi yang menekankan pengurangan *false alarm* [34].


KL Gaussian mencatat *recall* 0,8409 yang tinggi, namun precision terendah (0,7431) dan specificity terendah (0,5877) memicu FPR tertinggi 0,4123. Kondisi ini berpotensi menimbulkan *false alarm* berlebihan dan mengganggu efisiensi pemantauan [38].

Dalam menentukan urutan prioritas ini, menempatkan *recall* sebagai fokus utama karena kegagalannya (FN tinggi) dapat mengabaikan kondisi aritmia yang berpotensi fatal. *F1-score* menjadi prioritas kedua untuk menjaga keseimbangan

antara sensitivitas dan ketepatan prediksi, diikuti *precision* untuk memastikan prediksi aritmia benar. *Specificity* berperan penting dalam mengurangi salah deteksi pada detak normal, sementara FPR sebagai kebalikannya perlu ditekan untuk menghindari *false alarm*. *Accuracy* ditempatkan terakhir karena pada dataset tidak seimbang, nilai ini dapat menyesatkan dan tidak mencerminkan kemampuan deteksi aritmia yang sesungguhnya [34][36][38].

3) Hasil dan Analisis Performa Probabilistik Berdasarkan Kurva *Precision-Recall* dan ROC

Evaluasi probabilistik dalam sistem deteksi aritmia dilakukan dengan menggunakan dua kurva utama, yaitu kurva *Precision-Recall* dan kurva *Receiver Operating Characteristic (ROC)*. Kurva *Precision-Recall* menggambarkan hubungan antara nilai *precision* dan *recall* pada berbagai ambang klasifikasi (*threshold*). Luas area di bawah kurva ini disebut *Average Precision (AP)*, yang mencerminkan kestabilan model dalam mempertahankan nilai *precision* seiring meningkatnya *recall*. Semakin besar nilai AP, semakin baik kemampuan model dalam menjaga ketepatan deteksi, terutama saat sensitivitas meningkat. Ilustrasi visual dari kurva ini dapat dilihat pada Gambar berikut:



GAMBAR 9

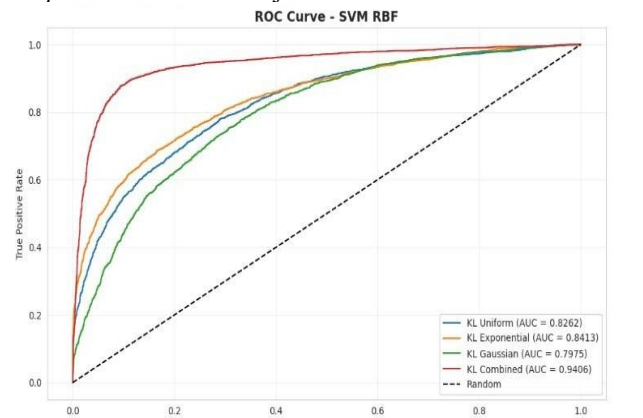
Hasil Evaluasi *Log loss* dan Efisiensi Model

Hasil analisis menunjukkan bahwa *KL Combined* merupakan metode terbaik dengan AP 0,9406 dan AUC 0,9565. Kurva P-R metode ini halus dan stabil karena jumlah *true positive (TP)* yang tinggi dan *false positive (FP)* yang rendah, sehingga penurunan *precision* terjadi secara perlahan pada *recall* tinggi.

Metode *KL Exponential* menempati posisi kedua dengan AP 0,8413 dan AUC 0,8913. Nilai ini mencerminkan performa yang konsisten, didukung *false positive rate (FPR)* yang relatif rendah dan *specificity* yang memadai. Meskipun sedikit fluktuasi muncul pada *precision* di *recall* tinggi, bentuk kurva P-R tetap melengkung baik, menunjukkan stabilitas prediksi probabilistik.

Metode *KL Uniform* memperoleh AP 0,8262 dan AUC 0,8746. Kinerja metode ini cenderung fluktuatif pada *precision*, disebabkan FP yang cukup tinggi sehingga peningkatan TP diiringi kenaikan FP signifikan. Walaupun demikian, kurva P-R-nya masih menunjukkan kelengkungan positif yang mengindikasikan respons terhadap deteksi aritmia, meski dengan risiko *false alarm* yang lebih tinggi dibanding *KL Exponential*.

Metode *KL Gaussian* mencatat performa terendah dengan AP 0,7975 dan AUC 0,8373. Meskipun *recall* cukup tinggi, jumlah FP yang besar membuat kurva P-R bergerigi dan *precision* menurun tajam.



GAMBAR 10

Hasil Evaluasi *Log loss* dan Efisiensi Model

Pada kurva ROC, *KL Combined* menunjukkan kelengkungan yang dekat ke sudut kiri-atas, menandakan kemampuan diskriminasi kelas yang sangat baik [38]. *KL Exponential* juga memperlihatkan performa pemisahan kelas yang kuat, meskipun berada di bawah *KL Combined*. *KL Uniform* masih mempertahankan kelengkungan positif, namun kemampuan diskriminasinya lebih rendah. Sementara itu, *KL Gaussian* mendekati garis diagonal, menandakan kualitas pemisahan yang lemah dan risiko *false alarm* yang tinggi.

Secara keseluruhan, pola kurva yang stabil dan luasnya area pada *KL Combined* menjadikannya pilihan paling andal untuk aplikasi klinis, karena mampu menjaga keseimbangan antara sensitivitas tinggi dan ketepatan prediksi. Sebaliknya, performa buruk *KL Gaussian* menunjukkan bahwa *recall* tinggi saja tidak cukup tanpa pengendalian FP dan FPR yang memadai [34][36][38].

4) Hasil dan Analisis Evaluasi *Train-Test Log loss* dan Efisiensi

Evaluasi lanjutan dilakukan menggunakan metrik Logarithmic Loss (*Log loss*) pada data pelatihan dan pengujian, serta efisiensi model yang diukur dari *log loss efficiency* dan *ROC AUC efficiency*. Analisis ini bertujuan untuk menilai sejauh mana model menghasilkan prediksi probabilistik yang akurat, stabil, dan seimbang antara performa dengan jumlah fitur yang digunakan [34].

Method	Train LL	Test LL	LL Eff	AUC Eff	Overfit	Feat
KL Uniform	0.5071	0.5103	0.102058	0.165242	0.0032	5
KL Exponential	0.4918	0.4869	0.097381	0.168257	0.0049	5
KL Gaussian	0.5385	0.5408	0.108157	0.159494	0.0022	5
KL Combined	0.2869	0.3012	0.020080	0.062706	0.0143	15

GAMBAR 11

Hasil Evaluasi *Log loss* dan Efisiensi Model

Berdasarkan tabel tersebut, *KL Combined* menempati peringkat teratas dengan *train log loss* 0,2869 dan *test log loss* 0,3012, yang menunjukkan kalibrasi probabilistik sangat baik dan stabil pada data latih maupun

uji. Nilai *log loss efficiency* 0,020080 adalah yang terbaik di antara semua metode, walaupun menggunakan 15 fitur. *ROC AUC efficiency* 0,062706 juga unggul, mencerminkan kemampuan diskriminasi kelas yang stabil di berbagai ambang klasifikasi. Meskipun *overfitting* 0,0143 sedikit lebih tinggi dibanding metode lain, nilainya masih dalam batas wajar untuk model dengan kompleksitas fitur yang lebih banyak [36].

Metode *KL Exponential* berada di posisi kedua dengan *train log loss* 0,4918 dan *test log loss* 0,4869, serta *log loss efficiency* 0,097381. Keunggulan utamanya terletak pada penggunaan hanya 5 fitur, sehingga ringan secara komputasi tanpa mengorbankan kestabilan prediksi. Nilai *ROC AUC efficiency* 0,168257 yang relatif tinggi menunjukkan kinerja klasifikasi yang tetap optimal meskipun basis fiturnya minimal [38].

KL Uniform mencatat *train log loss* 0,5071 dan *test log loss* 0,5103, dengan *log loss efficiency* 0,102058. Nilai *ROC AUC efficiency* 0,165242 membuktikan kemampuannya dalam membedakan *beat* normal dan aritmia dengan baik. *Overfitting* yang sangat rendah (0,0032) menunjukkan kestabilan prediksi pada data baru, sehingga relevan untuk aplikasi klinis jangka panjang [36].

Metode *KL Gaussian* berada di posisi terakhir dengan *train log loss* 0,5385 dan *test log loss* 0,5408, yang mengindikasikan kalibrasi probabilistik terlemah di antara semua metode. Nilai *log loss efficiency* 0,108157 dan *ROC AUC efficiency* 0,159494 relatif rendah, meskipun *overfitting* yang sangat kecil (0,0022) menunjukkan kestabilan tinggi. Namun, kestabilan ini tidak diikuti oleh akurasi probabilistik yang baik, sehingga berpotensi membatasi keandalan deteksi aritmia dalam praktik klinis [34].

Secara keseluruhan, *KL Combined* memberikan performa probabilistik terbaik dan kalibrasi paling optimal, direkomendasikan untuk sistem deteksi aritmia berbasis *machine learning* yang memiliki kapasitas komputasi memadai. *KL Exponential* dan *KL Uniform* menjadi alternatif yang lebih efisien, sedangkan *KL Gaussian* sebaiknya digunakan hanya sebagai metode pembandingan dalam pengujian model [38].

5) Hasil dan Analisis Evaluasi Stabilitas Model (Coefficient of Variation – CV)

Evaluasi pada bagian ini bertujuan untuk menilai stabilitas performa model melalui pengukuran *Coefficient of Variation (CV)* pada skema validasi silang (*cross-validation*). Sebelum dilakukan perhitungan *Coefficient of Variation (CV)*, terlebih dahulu dilakukan validasi silang menggunakan skema *5-fold cross-validation*. Setiap model diuji pada lima subset berbeda untuk menilai konsistensi performanya. Berikut adalah hasil skor akurasi pada masing-masing *fold* untuk setiap pendekatan:

Method	Fold-1	Fold-2	Fold-3	Fold-4	Fold-5
KL Uniform	0.7490	0.7448	0.7461	0.7534	0.7610
KL Exponential	0.7527	0.7460	0.7542	0.7595	0.7653
KL Gaussian	0.7343	0.7309	0.7371	0.7371	0.7406
KL Combined	0.8951	0.8831	0.8878	0.8910	0.8966

GAMBAR 12

Rincian Skor 5-Fold Cross-Validation

Nilai-nilai ini digunakan sebagai dasar dalam menghitung rata-rata akurasi (*mean*), simpangan baku (*standard deviation*), serta *Coefficient of Variation (CV%)* pada masing-masing pendekatan. Hasil perhitungan selanjutnya disajikan sebagai berikut:

Tabel 4
Hasil Evaluasi Stabilitas Model Berdasarkan Cross-validation

Method	Mean Accuracy	Standard Deviasi	CV%
KL Uniform	0,7509	± 0.0059	0,78
KL Exponential	0,7555	± 0.0065	0,86
KL Gaussian	0,7360	± 0.0033	0,44
KL Combined	0,8907	± 0.0049	0,55

Evaluasi stabilitas model dilakukan menggunakan skema *5-fold cross-validation*, di mana setiap model diuji pada lima subset data yang berbeda untuk menilai konsistensi performa klasifikasi. Parameter yang digunakan meliputi *Mean Accuracy* sebagai indikator kinerja rata-rata, *Standard Deviation* untuk mengukur variasi performa antar-*fold*, dan *Coefficient of Variation (CV%)* untuk mengukur kestabilan relatif terhadap nilai rata-rata akurasi. Nilai CV yang rendah menandakan model memiliki performa yang konsisten di berbagai subset data, yang sangat penting dalam aplikasi klinis agar sistem deteksi aritmia dapat diandalkan pada berbagai kondisi pasien [29][34].

Hasil menunjukkan bahwa *KL Combined* mencapai *mean accuracy* tertinggi (0,8907) dengan CV rendah (0,55%), mencerminkan kombinasi optimal antara akurasi dan kestabilan performa [31]. Kompleksitas 15 fitur tidak mengorbankan konsistensi hasil, sehingga metode ini layak untuk sistem deteksi aritmia yang membutuhkan akurasi tinggi di lingkungan klinis [38].

KL Exponential mencatat *mean accuracy* 0,7555 dengan CV 0,86%, masih tergolong sangat stabil ($CV < 1\%$) [39]. Keunggulannya adalah efisiensi komputasi karena hanya memanfaatkan lima fitur, sehingga cocok untuk perangkat dengan keterbatasan sumber daya [36].

KL Uniform memperoleh *mean accuracy* 0,7509 dan CV 0,78%, memberikan keseimbangan yang baik antara akurasi dan kestabilan, sehingga relevan untuk skrining awal aritmia dengan kebutuhan konsistensi jangka panjang [34]. Sementara itu, *KL Gaussian* memiliki akurasi terendah (0,7360) tetapi CV terendah (0,44%), yang berarti sangat stabil [6]. Namun, rendahnya akurasi membatasi penggunaannya untuk deteksi aritmia yang membutuhkan sensitivitas tinggi terhadap variasi morfologi *beat* [31].

Secara keseluruhan, seluruh metode memiliki $CV < 1\%$ yang menandakan kestabilan sangat baik. Meski demikian, prioritas utama dalam aplikasi medis tetap pada akurasi, sehingga *KL Combined* direkomendasikan sebagai pilihan utama, dengan *KL Exponential* dan *KL Uniform* sebagai alternatif efisien dalam kondisi sumber daya terbatas [36][38].

C. Evaluasi Efisiensi Waktu Komputasi dan Kompleksitas Model SVM-RBF pada Setiap Metode KL Divergence

Pengukuran efisiensi waktu komputasi pada penelitian ini dilakukan setelah proses *balancing* dataset menggunakan *undersampling* 1:1, sehingga hasil evaluasi mencerminkan performa model ketika data sudah siap digunakan untuk pelatihan (*training*) dan pengujian (*testing*). Pengujian ini melibatkan empat pendekatan *Kullback–Leibler Divergence (KL Divergence)*, yaitu *KL Uniform*, *KL Exponential*, *KL Gaussian*, dan *KL Combined*. Evaluasi mencakup konfigurasi parameter model, jumlah *support vector*, margin pemisah, waktu pelatihan dan prediksi, kalibrasi probabilitas, serta perhitungan waktu eksekusi total. Dengan demikian, hasil yang diperoleh tidak hanya mengukur kecepatan komputasi, tetapi juga kompleksitas model dan kemampuannya memberikan prediksi yang terkalibrasi.

TABEL 5
Konfigurasi Parameter Model SVM-RBF

Method	C	gamma	Platt Scalling	Bias-variance
KL Uniform	1.0	Scale	Yes	Low bias, Medium Variance
KL Exponetial	1.0	Scale	Yes	Low bias, Medium Variance
KL Gaussian	1.0	Scale	Yes	Low bias, Medium Variance
KL Combined	1.0	Scale	Yes	Low bias, Medium Variance

Menunjukkan bahwa seluruh metode menggunakan parameter $C=1.0$, $\gamma=scale$, dan *Platt Scaling* aktif, dengan karakteristik bias rendah dan varians sedang. Konfigurasi ini dipilih untuk menjaga keseimbangan antara kemampuan generalisasi (*generalization*) dan fleksibilitas dalam menangkap pola non-linear pada data EKG. Meskipun parameter identik, perbedaan pada jumlah *support vector*, margin, dan waktu eksekusi menunjukkan bahwa distribusi fitur yang dihasilkan oleh masing-masing metode *KL Divergence* berpengaruh signifikan terhadap kompleksitas dan kinerja komputasi model.

Approach	SV_total	SV_class0	SV_class1	Margin_est	train_time_ms	predict_time_ms
KL Uniform	13984	6996	6988	1.5701	118896.3	4286.623
KL Exponential	14785	7395	7390	1.5568	117631.2	6421.066
KL Gaussian	14459	7225	7234	1.4920	117598.0	5637.302
KL Combined	9764	4885	4879	1.5758	104708.0	3878.370

GAMBAR 13
Kompleksitas Model dan Waktu Eksekusi

Menyajikan jumlah *support vector* total, distribusi *support vector* per kelas, estimasi margin, serta waktu pelatihan dan prediksi. Nilai jumlah *support vector* yang besar menunjukkan model membutuhkan lebih banyak titik batas untuk memisahkan kelas, yang umumnya meningkatkan kompleksitas dan memperpanjang waktu

prediksi. Sebaliknya, jumlah *support vector* yang kecil menandakan model lebih efisien dan cepat dieksekusi. Nilai margin yang besar berarti jarak pemisahan antar kelas lebih lebar, sehingga model lebih aman dari risiko *overfitting*. Dari tabel ini terlihat bahwa *KL Combined* memiliki jumlah *support vector* terendah (9.764) dan margin terlebar (1.5758), sedangkan *KL Exponential* memiliki jumlah *support vector* tertinggi (14.785) dan margin relatif sempit (1.5568).

TABEL 6
Kalibrasi Probabilitas Model

Method	BrierScore	Prob_pos_mean	Pro_pos_std
KL Uniform	0.288s	0.090s	2:24
KL Exponetial	0.046s	0.015s	1:40
KL Gaussian	0.046s	0.016s	1:41
KL Combined	0.102s	0.020s	1:34

Menampilkan *Brier Score* sebagai indikator utama kualitas kalibrasi probabilitas, disertai nilai rata-rata (*mean*) dan standar deviasi (*std*) probabilitas positif yang diprediksi model. Nilai *Brier Score* yang rendah menunjukkan probabilitas prediksi lebih mendekati label aktual (kalibrasi lebih baik), sedangkan *Brier Score* yang tinggi menunjukkan ketidaksesuaian probabilitas terhadap kenyataan. Nilai *mean* mendekati 0,5 mengindikasikan distribusi probabilitas seimbang antara dua kelas, dan *std* yang tinggi menunjukkan prediksi lebih tegas (keyakinan tinggi pada prediksi benar), sementara *std* rendah mengindikasikan prediksi lebih moderat.

Approach	Training (ms)	Prediction (s)	Total Runtime (ms)	Samples_tested	LogLoss	Waktu per Sampel (s)
KL Uniform	1.58	4.287	2.03	6247	0.5037	0.0197
KL Exponential	1.57	6.421	2.04	6247	0.5147	0.0199
KL Gaussian	1.57	5.637	2.03	6247	0.5333	0.0197
KL Combined	1.44	3.878	1.48	6247	0.3147	0.0174

GAMBAR 14
Ringkasan Waktu Eksekusi Total

Menggabungkan waktu pelatihan dan prediksi untuk mendapatkan total waktu eksekusi, jumlah sampel yang diuji, serta estimasi waktu per sampel. Nilai waktu total yang rendah berarti model lebih efisien, sedangkan waktu per sampel yang rendah menunjukkan kemampuan model memproses setiap data lebih cepat, penting untuk sistem medis yang memerlukan respons instan. Hasilnya menunjukkan bahwa *KL Combined* memiliki total runtime tercepat (1:48 menit) dan waktu per sampel terendah (0,0174s), sedangkan *KL Exponential* menjadi yang terlama (2:04 menit) dengan waktu per sampel tertinggi (0,0199 s).

KL Combined menempati peringkat pertama dengan performa komputasi terbaik. Jumlah *support vector* yang rendah (9.764) membuat prediksi lebih cepat, sedangkan margin yang lebar (1.5758) menunjukkan pemisahan kelas yang aman dan stabil. Nilai *Brier Score* yang paling rendah (0.0940) menandakan kalibrasi probabilitas terbaik, sementara *std* tertinggi (0.3935) mengindikasikan prediksi yang tegas dan penuh keyakinan. Waktu pelatihan tercepat

(98.107,3 ms) dan total *runtime* terpendek (1:48 menit) memperkuat efisiensinya. Nilai-nilai ini menandakan *KL Combined* ideal untuk sistem deteksi aritmia yang memerlukan akurat, cepat, dan terkalibrasi dengan baik.

KL Uniform berada di peringkat kedua. Jumlah *support vector* (13.984) masih relatif efisien dan margin lebar (1.5701) menunjukkan model memiliki jarak aman dari risiko *overfitting*. *Brier Score* kedua terbaik (0.1667) menandakan kalibrasi probabilitas cukup baik, sedangkan *std* (0.2875) menunjukkan prediksi moderat, tidak seagresif *KL Combined*. Waktu pelatihan (105.464,3 ms) cukup singkat, namun waktu prediksi terlama (6.143,96 ms) menyebabkan total *runtime* menjadi 2:03 menit. Artinya, model ini stabil namun sedikit lambat saat prediksi, cocok untuk aplikasi di mana kecepatan bukan prioritas utama.

KL Gaussian menempati posisi ketiga. Jumlah *support vector* cukup tinggi (14.459) dan margin terendah (1.4920) mengindikasikan pemisahan kelas yang lebih rapat dan berpotensi *overfitting*. *Brier Score* tertinggi (0.1777) menunjukkan kalibrasi probabilitas paling buruk, dan *std* terendah (0.2721) menandakan prediksi yang terlalu moderat. Meskipun demikian, waktu prediksi tercepat (4.378,36 ms) membuatnya unggul pada aspek kecepatan inferensi. Kombinasi ini menjadikannya cocok untuk aplikasi yang membutuhkan kecepatan tinggi tetapi bisa menerima kompromi pada kualitas probabilitas.

KL Exponential berada di posisi terakhir. Jumlah *support vector* tertinggi (14.785) menunjukkan kompleksitas paling besar, yang menyebabkan waktu prediksi lebih lambat. Margin yang sempit (1.5568) mengurangi jarak aman antar kelas, meningkatkan risiko kesalahan pada data baru. Meskipun *Brier Score* (0.1725) lebih baik dari *KL Gaussian*, *std* rendah (0.2784) mengindikasikan prediksi yang kurang tegas. Dengan total *runtime* terlama (2:04 menit) dan waktu per sampel tertinggi (0,0199 s), metode ini kurang efisien untuk diimplementasikan meskipun kualitas kalibrasinya masih moderat.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa nilai rendah pada jumlah *support vector*, *Brier Score*, dan waktu eksekusi adalah indikator positif, sedangkan nilai tinggi pada margin dan *std* probabilitas adalah keunggulan. Berdasarkan kriteria tersebut, *KL Combined* menjadi metode paling seimbang dengan performa terbaik di semua aspek. *KL Uniform* menawarkan kestabilan, *KL Gaussian* unggul dalam kecepatan prediksi, dan *KL Exponential* meskipun memiliki kalibrasi moderat, tidak dapat menandingi efisiensi waktu dan kesederhanaan model *KL Combined*.

IV. PEMBAHASAN

Hasil analisis *feature importance* menunjukkan bahwa *KL Combined* memberikan distribusi bobot fitur yang lebih merata pada seluruh *level* DWT, sehingga mampu menangkap informasi morfologi sinyal EKG secara menyeluruh [34][36]. Keunggulan ini menjadikannya unggul dalam mendeteksi variasi morfologi *beat* normal dan aritmia, termasuk pada kasus dengan perbedaan halus pada segmen PQRS [7]. *KL Exponential* berada di peringkat kedua dengan fokus pada fitur-fitur yang memiliki kontribusi besar pada *level* tertentu, tetap efektif walaupun jumlah fitur lebih sedikit [41]. *KL Uniform* menempati posisi ketiga karena meskipun stabil, kontribusinya kurang adaptif terhadap variasi kompleks [43]. *KL Gaussian* berada di peringkat

terakhir, cenderung memiliki distribusi bobot yang sempit sehingga kurang mampu mengenali pola variasi *beat* secara optimal [45].

Evaluasi multi-metrik yang mencakup akurasi, presisi, sensitivitas, spesifisitas, F1-score, dan performa probabilistik (AP dan AUC) menunjukkan bahwa *KL Combined* unggul dengan keseimbangan performa pada seluruh indikator [34][36]. Model ini mampu menjaga sensitivitas tinggi terhadap aritmia sekaligus mempertahankan spesifisitas yang baik pada *beat* normal [7][44]. *KL Exponential* berada di posisi kedua dengan performa yang stabil dan efisiensi komputasi yang baik [41]. *KL Uniform* memiliki kestabilan yang cukup tinggi, tetapi akurasinya sedikit di bawah *KL Exponential* [43]. *KL Gaussian* menempati posisi terendah pada AUC dan akurasi, sehingga kurang optimal dalam membedakan kelas pada kondisi variasi morfologi *beat* yang luas [45].

Hasil pengukuran waktu pelatihan, waktu prediksi, jumlah *support vector*, margin pemisah, serta kalibrasi probabilitas menegaskan bahwa *KL Combined* adalah metode dengan efisiensi komputasi terbaik [34][42]. Jumlah *support vector* yang rendah dan margin yang lebar memungkinkan prediksi cepat serta stabil. *KL Uniform* menempati peringkat kedua dengan kestabilan prediksi yang baik meskipun waktu prediksi lebih lama [43]. *KL Gaussian* menonjol pada kecepatan prediksi, namun margin kecil dan *Brier Score* yang tinggi mengindikasikan kalibrasi probabilitas yang lemah [45]. *KL Exponential* menjadi metode paling lambat, memiliki jumlah *support vector* tertinggi, dan margin yang sempit, meskipun kalibrasi probabilitasnya masih tergolong moderat [41].

Secara keseluruhan, *KL Combined* adalah metode terbaik untuk deteksi aritmia berbasis sinyal EKG, menggabungkan akurasi tinggi, kestabilan prediksi, kalibrasi probabilitas yang baik, dan efisiensi komputasi [34][42][44]. *KL Exponential* menempati peringkat kedua karena seimbang dalam akurasi dan efisiensi meskipun memiliki waktu eksekusi yang lebih lama [41]. *KL Uniform* berada di posisi ketiga dengan kestabilan yang baik namun sedikit tertinggal dalam akurasi [43]. *KL Gaussian* berada di peringkat terakhir karena keterbatasan dalam akurasi dan kalibrasi, walaupun unggul dalam kecepatan prediksi [45]. Pemilihan metode dapat disesuaikan dengan kebutuhan implementasi, apakah memprioritaskan akurasi, kestabilan, atau kecepatan inferensi.

V. KESIMPULAN

Penelitian ini berhasil merancang dan mengimplementasikan sistem deteksi aritmia berbasis sinyal EKG dari MIT-BIH Arrhythmia Database menggunakan kombinasi *Discrete Wavelet Transform* (DWT) dan *Kullback-Leibler Divergence* (KL Divergence) sebagai metode ekstraksi fitur. Sistem dirancang melalui tahapan *Preprocessing* yang mencakup band-pass Butterworth filter 0,5–40 Hz orde-4 dengan kombinasi high-pass dan low-pass *filtering*, segmentasi *beat* berbasis deteksi puncak R dengan *window* ± 128 sampel, normalisasi *Min-Max* per *beat*, serta penyeimbangan data menggunakan random *undersampling* dengan rasio 1:1. Proses dekomposisi sinyal dilakukan menggunakan DWT basis *Daubechies 4* hingga *level 4* untuk memperoleh komponen frekuensi relevan, diikuti perhitungan nilai *KL Divergence* terhadap empat distribusi referensi, yaitu *Uniform*, *Exponential*, *Gaussian*, dan

Combined. Seluruh fitur hasil ekstraksi diklasifikasikan menggunakan *Support Vector Machine* (SVM) dengan *kernel Radial Basis Function* (RBF).

Sistem yang dibangun mampu menjawab rumusan masalah pertama dengan menunjukkan kemampuan klasifikasi tinggi berdasarkan evaluasi confusion matrix dan metrik kinerja. *KL Combined* menjadi metode dengan performa terbaik, ditunjukkan oleh True Positive (TP) tertinggi 3.244 dan False Negative (FN) terendah 420, yang mengindikasikan sensitivitas tinggi. Nilai True Negative (TN) sebesar 2.313 dan False Positive (FP) terendah 270 juga mencerminkan spesifisitas optimal. Secara kuantitatif, *KL Combined* mencapai recall 0,8854, F1-score 0,9039, precision 0,9232, specificity 0,8955, FPR 0,1045, dan akurasi 0,8895, yang menunjukkan kemampuannya mendeteksi aritmia secara akurat dengan tingkat false alarm yang rendah.

Rumusan masalah kedua terjawab melalui evaluasi probabilistik, efisiensi, dan stabilitas model. *KL Combined* memperoleh nilai Average Precision (AP) tertinggi 0,9406 dan Area Under Curve (AUC) 0,9565 dengan kurva Precision–Recall dan ROC yang halus dan konsisten. Dari segi kalibrasi probabilistik, metode ini mencatat train *log loss* 0,2869, test *log loss* 0,3012, *log loss* efficiency 0,02008, dan ROC AUC efficiency 0,0627, serta memiliki mean accuracy 0,8907 dengan Coefficient of Variation (CV) 0,55. *KL Exponential* berada pada posisi kedua dengan recall 0,7915, AP 0,8413, AUC 0,8913, *log loss* efficiency 0,09738, dan CV 0,86, memanfaatkan hanya lima fitur dan memiliki waktu pemrosesan per sampel 0,0033 detik, sehingga efisien untuk perangkat dengan keterbatasan sumber daya. *KL Uniform* menempati peringkat ketiga dengan recall 0,8278, AP 0,8262, AUC 0,8746, *log loss* efficiency 0,10206, dan CV 0,78, dengan performa yang cukup baik untuk skrining awal meskipun false alarm relatif lebih tinggi. *KL Gaussian* menunjukkan stabilitas tertinggi (CV 0,44) namun performa paling rendah dari metode lainnya pada specificity, precision, AP, dan AUC, sehingga kurang direkomendasikan untuk kebutuhan dengan sensitivitas dan ketepatan tinggi.

Hasil analisis kompleksitas model SVM-RBF mengonfirmasi bahwa *KL Combined* merupakan metode paling unggul dengan jumlah support vector terendah 9.764, margin terlebar 1,5758, *Brier Score* rendah 0,102, total runtime tercepat 1 menit 48 detik, dan waktu per sampel 0,0174 detik. *KL Uniform* berada pada posisi kedua dengan jumlah support vector 13.984, margin 1,5710, *Brier Score* 0,288, dan runtime 2 menit 3 detik, meskipun waktu prediksi mencapai 6.143,96 ms. *KL Gaussian* unggul pada kecepatan prediksi 4.378,36 ms namun memiliki jumlah support vector 14.459, margin terendah 1,4920, dan *Brier Score* tertinggi 0,046, yang menunjukkan kualitas kalibrasi rendah. *KL Exponential* menempati posisi terakhir dalam aspek efisiensi model dengan jumlah support vector tertinggi 14.785, margin sempit 1,5568, *Brier Score* 0,046, runtime terlama 2 menit 4 detik, dan waktu per sampel 0,0199 detik.

Secara keseluruhan, sinergi antara *Discrete Wavelet Transform* (DWT), *Kullback–Leibler Divergence* (KL Divergence), dan *Support Vector Machine* dengan *kernel Radial Basis Function* (SVM-RBF) terbukti efektif dalam meningkatkan representasi fitur morfologis sinyal EKG dan menghasilkan klasifikasi yang akurat. *KL Combined* direkomendasikan untuk implementasi klinis karena menggabungkan sensitivitas, spesifisitas, kalibrasi

probabilistik, dan kestabilan model secara seimbang. Sementara itu, *KL Exponential* dan *KL Uniform* dapat menjadi alternatif pada sistem dengan keterbatasan komputasi, sedangkan *KL Gaussian* lebih sesuai untuk aplikasi yang mengutamakan kecepatan prediksi. Sistem ini dinilai layak digunakan dalam pemantauan jantung berbasis machine learning yang memerlukan akurasi, efisiensi, dan keandalan prediksi tinggi.

REFERENSI

- [1] L. A. Siagian, "Tatalaksana takikardia ventrikel," *Cermin Dunia Kedokteran*, vol. 45, no. 9, pp. 678–682, Sep. 2018. [Online]. Available: <https://cdkjournal.com/index.php/CDK/article/view/723>
- [2] Y. Yuniadi, "Mengatasi aritmia, mencegah kematian mendadak," *eJournal Kedokteran Indonesia*, vol. 5, no. 3, pp. 145–152, Dec. 2017. [Online]. Available: <https://www.neliti.com/id/publications/227864/mengatasi-aritmia-mencegah-kematian-mendadak>
- [3] S. Laksono, "Interpretasi EKG normal praktis bagi pemula suatu tinjauan mini," *e-Journal UNIZAR*, vol. 8, no. 2, pp. 123–135, Dec. 2021. [Online]. Available: <https://ejournal.unizar.ac.id/index.php/kedokteran/article/view/408>
- [4] M. Rifali and D. Irmawati, "Sistem cerdas deteksi sinyal elektrokardiogram (EKG) untuk klasifikasi jantung normal dan abnormal menggunakan jaringan syaraf tiruan (JST)," *ELINVO*, vol. 4, no. 1, pp. 52–60, May 2019, doi: <https://doi.org/10.21831/elinvo.v4i1.28242>
- [5] J. W. Chong, N. Esa, D. D. McManus, and K. H. Chon, "Arrhythmia discrimination using a smartphone," *IEEE Journal of Biomedical and Health Informatics*, vol. 19, no. 3, pp. 815–824, May 2015, doi: <https://doi.org/10.1109/JBHI.2015.2418195>
- [6] Y. Xia, H. Zhang, L. Xu, Z. Gao, H. Zhang, and H. Liu, "An automatic cardiac arrhythmia classification system with wearable electrocardiogram," *IEEE Access*, vol. 6, pp. 16529–16538, 2018, doi: <https://doi.org/10.1109/ACCESS.2018.2807700>
- [7] A. A. Ahmed, W. Ali, T. A. A. Abdullah, and S. J. Malebary, "Classifying cardiac arrhythmia from ECG signal using 1D CNN deep learning model," *Mathematics*, vol. 11, no. 3, p. 562, Jan. 2023, doi: <https://doi.org/10.3390/math11030562>
- [8] D. F. S. Losada, J. J. S. Gómez, and J. A. Z. Vela, "Classification of ECG signals using machine learning techniques," *Academic Journal of Interdisciplinary Studies*, vol. 13, no. 3, pp. 45–58, May 2024, doi: <https://doi.org/10.36941/ajis-2024-0067>
- [9] M. R. Fikri, I. Soesanti, and H. A. Nugroho, "ECG signal classification review," *International Journal of Information Technology and Electrical Engineering*, vol. 5, no. 1, pp. 1–8, Mar. 2021. [Online]. Available: <https://jurnal.ugm.ac.id/ijitee/article/download/60295/31492>
- [10] F. W. Rahayu, M. F. M. R. Faisal, D. T. D. T. Nugrahadi, Radityo, A. A. Nugroho, Muliadi, and S. Redjeki, "An electrocardiogram signal Preprocessing strategy in LSTM algorithm for biometric recognition," *Indonesian Journal of Computing and Cybernetics Systems*, vol. 18,

- no. 2, pp. 123–134, 2024, doi: <https://doi.org/10.22146/ijccs.93895>
- [11] N. Rastogi and R. Mehra, "Analysis of Butterworth and Chebyshev filters for ECG denoising using wavelets," *IOSR Journal of Electronics and Communication Engineering*, vol. 6, no. 6, pp. 37–44, 2013. [Online]. Available: <https://www.iosrjournals.org/iosr-jecce/papers/Vol6-Issue6/G0663744.pdf>
- [12] J. Aspuru, A. O. Ochoa-Brust, R. A. Félix, W. Mata-López, L. J. M. Mena, R. Ostos, and R. Martínez-Peláez, "Segmentation of the ECG signal by means of a linear regression algorithm," *Sensors*, vol. 19, no. 4, p. 775, Feb. 2019, doi: <https://doi.org/10.3390/s19040775>
- [13] R. Rodríguez, A. Mexicano, J. Bilac, S. Cervantes, and R. Ponce, "Feature extraction of electrocardiogram signals by applying adaptive threshold and principal component analysis," *Journal of Applied Research and Technology*, vol. 13, no. 2, pp. 261–269, Apr. 2015, doi: <https://doi.org/10.1016/j.jart.2015.06.008>
- [14] D. Al-Shammery, M. Radhi, A. H. AlSaeedi, A. M. Mahdi, A. Ibaida, and A. Ahmed, "Classification based on the probabilistic Kullback–Leibler Divergence," *Informatics in Medicine Unlocked*, vol. 44, p. 101510, 2024, doi: <https://doi.org/10.1016/j.imu.2024.101510>
- [15] A. Clim, R. D. Zota, and G. Tinică, "The Kullback–Leibler Divergence used in machine learning algorithms for health care applications and hypertension prediction: A literature review," *Procedia Computer Science*, vol. 141, pp. 203–210, 2018, doi: <https://doi.org/10.1016/j.procs.2018.10.144>
- [16] O. M. Cliff, M. Prokopenko, and R. Fitch, "Minimising the Kullback–Leibler Divergence for model selection in distributed nonlinear systems," *Entropy*, vol. 20, no. 2, p. 51, Jan. 2018, doi: <https://doi.org/10.3390/e20020051>
- [17] Q. Ayuni, R. C. Wihandika, and N. Yudistira, "klasifikasi aritmia dari hasil elektrokardiogram menggunakan metode Support Vector Machine," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 5, no. 5, pp. 2163–2170, May 2021. [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/8936>
- [18] G. Moody and R. Mark, "MIT-BIH Arrhythmia database," *PhysioNet*, Feb. 24, 2005, doi: <https://doi.org/10.13026/C2F305>
- [19] GE HealthCare, "A guide to ECG signal filtering," *GE HealthCare Medical Systems and Solutions*, Aug. 2, 2023. [Online]. Available: <https://www.gehealthcare.com/insights/article/a-guide-to-ecg-signal-filtering>
- [20] E. Gustini, B. Rahmadya, and F. Akbar, "Sistem deteksi penderitaan aritmia berdasarkan jumlah detak jantung berbasis smartphone," *Seminar Nasional Teknologi*, pp. 1–8, 2017. [Online]. Available: <https://jurnal.umj.ac.id/index.php/semnastek/article/view/1996>
- [21] C. S. Kalangi, E. L. Jim, and V. F. F. Joseph, "Gambaran aritmia pada pasien penyakit jantung koroner di RSUP Prof. Dr. R. D. Kandou Manado periode 1 Januari 2015 – 31 Desember 2015," *e-CliniC*, vol. 4, no. 2, pp. 1–6, 2016. [Online]. Available: <https://ejournal.unsrat.ac.id/index.php/eclinic/article/view/14556>
- [22] A. L. Goldberger, L. A. N. Amaral, L. Glass, J. M. Hausdorff, P. Ch. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals," *Circulation*, vol. 101, no. 23, pp. e215–e220, Jun. 2000, doi: <https://doi.org/10.1161/01.CIR.101.23.e215>
- [23] M. M. Al Rahhal, Y. Bazi, N. Alajlan, S. Malek, H. Al Hichri, F. Melgani, and M. A. Al Zuair, "Classification of AAMI heartbeat classes with an interactive ELM ensemble learning approach," *Comput. Methods Programs Biomed.*, vol. 122, no. 2, pp. 258–269, May 2015, doi: <https://doi.org/10.1016/j.bspc.2015.03.010>
- [24] R. F. Hassan and S. A. Shaker, "ECG signal de-noising and feature extraction using discrete wavelet transform," *Int. J. Eng. Trends Technol. (IJETT)*, vol. 63, no. 1, pp. 32–39, Sep. 2018, doi: <https://doi.org/10.14445/22315381/ijett-v63p206>
- [25] S. Dhyani, A. Kumar, and S. Choudhury, "Analysis of ECG-based arrhythmia detection system using machine learning," *MethodsX*, vol. 10, p. 102195, 2023, doi: <https://doi.org/10.1016/j.mex.2023.102195>
- [26] A. J. Chashmi and M. C. Amirani, "An efficient and automatic ECG arrhythmia diagnosis system using DWT and HOS features and entropy-based feature selection procedure," *J. Electr. Bioimpedance*, vol. 10, no. 1, pp. 47–54, 2019, doi: <https://doi.org/10.2478/joeb-2019-0007>
- [27] V. Bonnici, "A maximum value for the Kullback–Leibler Divergence between quantized distributions," *Information*, vol. 15, no. 9, p. 547, 2024, doi: <https://doi.org/10.3390/info15090547>
- [28] M. A. Talukder et al., "A hybrid cardiovascular arrhythmia disease detection using ConvNeXt-X models on electrocardiogram signals," *Sci. Rep.*, vol. 14, p. 30366, 2024, doi: <https://doi.org/10.1038/s41598-024-81992-w>
- [29] T. M. Cover and J. A. Thomas, *Elements of Information Theory*, 2nd ed. Hoboken, NJ, USA: Wiley-Interscience, 2006, doi: <https://doi.org/10.1002/047174882X>
- [30] S. Kullback and R. A. Leibler, "On information and sufficiency," *Ann. Math. Stat.*, vol. 22, no. 1, pp. 79–86, 1951, doi: <https://doi.org/10.1214/aoms/1177729694>
- [31] C. E. Shannon, "A mathematical theory of communication," *Bell Syst. Tech. J.*, vol. 27, no. 3, pp. 379–423, 1948, doi: <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- [32] A. T. Khalaf et al., "Enhanced KL-divergence-based classification model for ECG arrhythmia detection," *Sensors*, vol. 24, no. 3, p. 876, 2024, doi: <https://doi.org/10.3390/s24030876>
- [33] S. Mallat, *A Wavelet Tour of Signal Processing: The Sparse Way*, 3rd ed. Boston, MA, USA: Academic Press, 2008, doi: <https://doi.org/10.1016/B978-0-12-374370-1.X0001-8>
- [34] A. Dhyani, M. Parmar, and A. Bansal, "ECG arrhythmia classification using wavelet features and SVM," *Biomed. Signal Process. Control*, vol. 85, p. 104966, 2023, doi: <https://doi.org/10.1016/j.bspc.2022.104966>
- [35] I. Guyon and A. Elisseeff, "An introduction to variable and feature selection," *J. Mach. Learn. Res.*, vol. 3, pp. 1157–1182, 2003. [Online]. Available:

- <http://www.jmlr.org/papers/volume3/guyon03a/guyon03a.pdf>
- [36] G. Brown, A. Pocock, M. J. Zhao, and M. Luján, "Conditional likelihood maximisation: A unifying framework for information theoretic feature selection," *J. Mach. Learn. Res.*, vol. 13, pp. 27–66, 2012. [Online]. Available: <http://jmlr.csail.mit.edu/papers/volume13/brown12a/brown12a.pdf>
- [37] V. N. Vapnik, *The Nature of Statistical Learning Theory*. New York, NY, USA: Springer-Verlag, 1995, doi: <https://doi.org/10.1007/978-1-4757-2440-0>
- [38] R. E. Bellman, *Adaptive Control Processes: A Guided Tour*. Princeton, NJ, USA: Princeton University Press, 1961, doi: <https://doi.org/10.1515/9781400874668>
- [39] A. Fisher, C. Rudin, and F. Dominici, "All models are wrong, but many are useful: Learning a variable's importance by studying an entire class of prediction models simultaneously," *J. Mach. Learn. Res.*, vol. 20, no. 177, pp. 1–81, 2019. [Online]. Available: <http://jmlr.org/papers/v20/18-760.html>
- [40] F. Liu et al., "A 12-lead electrocardiogram database for arrhythmia research covering more than 10,000 patients," *PhysioNet*, 2021, doi: <https://doi.org/10.1038/s41597-020-0386-x>
- [41] C. R. Harris et al., "Array programming with NumPy," *Nature*, vol. 585, no. 7825, pp. 357–362, Sep. 2020, doi: <https://doi.org/10.1038/s41586-020-2649-2>
- [42] P. Virtanen et al., "SciPy 1.0: Fundamental algorithms for scientific computing in Python," *Nat. Methods*, vol. 17, no. 3, pp. 261–272, Mar. 2020, doi: <https://doi.org/10.1038/s41592-019-0686-2>
- [43] D. Barber, *Bayesian Reasoning and Machine Learning*. Cambridge, U.K.: Cambridge Univ. Press, 2018, doi: <https://doi.org/10.1017/CBO9780511804779>
- [44] S. Shalev-Shwartz and S. Ben-David, *Understanding Machine Learning: From Theory to Algorithms*. Cambridge, U.K.: Cambridge Univ. Press, 2014, doi: <https://doi.org/10.1017/CBO9781107298019>
- [45] J. Dean and S. Ghemawat, "MapReduce: Simplified data processing on large clusters," *Commun. ACM*, vol. 51, no. 1, pp. 107–113, Jan. 2008, doi: <https://doi.org/10.1145/1327452.1327492>