

# Analisis *Attractors non-linier* pada Sinyal *Heart Rate Variability (HRV)* untuk Deteksi Awal Penyakit Jantung Koroner

Maudy Apriana  
Program Studi Teknik Biomedis  
Fakultas Teknik Elektro  
Bandung, Indonesia

maudyapriana@student.telkomuniversity.ac.id

Tito Waluyo Purboyo  
Program Studi Teknik Biomedis  
Fakultas Teknik Elektro  
Bandung, Indonesia

titowaluyo@telkomuniversity.ac.id

Dziban Naufal  
Program Studi Teknik Biomedis  
Fakultas Teknik Elektro  
Bandung, Indonesia

dziban@telkomuniversity.ac.id

**Abstrak** — Penyakit jantung koroner (*Coronary Artery Disease/CAD*) merupakan salah satu penyebab kematian tertinggi di dunia yang seringkali terdeteksi pada tahap lanjut. Oleh karena itu, diperlukan metode deteksi dini yang cepat, non-invasif, dan efisien. Salah satu pendekatan yang potensial adalah pemanfaatan sinyal *Heart Rate Variability (HRV)*. Namun, metode analisis HRV konvensional berbasis pendekatan linier sering kali tidak mampu menangkap dinamika kompleks jantung yang bersifat *non-linier*. Penelitian ini mengusulkan pendekatan berbasis rekonstruksi ruang fase untuk mengungkap pola dinamis *non-linier* dari parameter HRV, yaitu SDRR (*Standar Deviation of RR intervals*) dan RMSSD (*Root Mean Square of Successive Differences*), pada dua lead sinyal elektrokardiogram (EKG) (*Lead II dan V1*). Gambar hasil *Phase Space Reconstruction (PSR)* dianalisis secara morfologis melalui uji Kolmogorov-Smirnov dua sampel, serta diklasifikasikan menggunakan dua arsitektur dari *Convolutional Neural Network (CNN)*, yakni VGG-16 dan LeNet. Hasil penelitian menunjukkan bahwa model CNN berbasis VGG-16 mampu mencapai akurasi yang tinggi dalam membedakan pola PSR antara pasien CAD dan individu normal. Pengujian Kolmogorov-Smirnov juga mendukung perbedaan signifikan distribusi ukuran geometris *attractors* antara kelas CAD dan normal.

**Kata kunci** — *Coronary Artery Disease, Heart Rate Variability, LeNet, Phase Space Reconstruction, VGG-16.*

## I. PENDAHULUAN

*Cardiovascular Disease (CVD)* atau penyakit kardiovaskular merupakan penyebab kematian utama secara global[1]. Dari 17 juta kematian dini (di bawah usia 70) akibat penyakit tidak menular, 38% disebabkan oleh CVD. Salah satu bentuk CVD yang paling umum dan berbahaya adalah Penyakit Jantung Koroner (PJK) atau *Coronary Artery Disease (CAD)*. Secara global, pada tahun 2022, jumlah kasus CAD mencapai 315 juta[2]. Sedangkan di Indonesia sendiri prevalensi CAD mencapai 1,9% kejadian tersebut menyerang semua kelompok umur.

CAD terjadi karena adanya masalah di pembuluh darah koroner yang menyebabkan penyempitan serta penyumbatan yang bisa mengganggu tahapan transportasi energi tubuh, juga dapat menjadikan ketidakseimbangan diantara kebutuhan oksigen serta suplai oksigen[3]. Untuk mendeteksi kondisi ini, salah satu modalitas diagnostik yang umum digunakan adalah Elektrokardiogram (EKG), yang merekam aktivitas listrik jantung secara non-invasif. Salah satu

informasi penting yang dapat diperoleh dari sinyal EKG adalah interval R-R, yaitu jarak waktu antar puncak gelombang R pada kompleks QRS. Ketika interval R-R diolah secara matematis dan statistik, akan dihasilkan parameter yang dikenal sebagai *Heart Rate Variability (HRV)*. Menganalisis gelombang-gelombang ini dapat membantu mengidentifikasi berbagai jenis penyakit jantung berdasarkan ukuran, bentuk, dan rentang frekuensinya. Namun, metode analisis HRV konvensional berbasis pendekatan linier sering kali tidak mampu menangkap dinamika kompleks jantung yang bersifat non-linier.

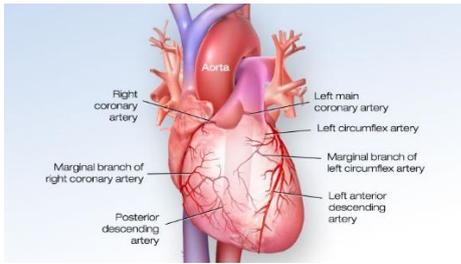
Karena memiliki ketergantungan non-linier pada variabel seperti potensial transmembran atau gradien konsentrasi ion melintasi dalam membran sel[4], sistem kardiovaskular dicirikan oleh berbagai bentuk perilaku, salah satunya deterministik chaos dan keacakan[5]. Hal ini dapat dikaitkan dengan fakta bahwa sinyal biomedis seperti EKG dapat dihasilkan oleh sistem dinamik *non-linier*. Metode analisis sinyal *non-linier* yang banyak dieksplorasi salah satunya adalah analisis rekonstruksi ruang fase[6]. Metode ini memungkinkan visualisasi dan karakterisasi struktur pola *non-linier* dari sinyal HRV, yang mencerminkan kondisi sistem kardiovaskular. Pendekatan ini berpotensi mendeteksi perubahan halus pada mekanisme kontrol kardiovaskular yang terjadi pada tahap awal CAD. Dengan rekonstruksi ruang fase, sinyal 1D diubah menjadi representasi 2D yang menggambarkan pola lintasan perilaku sistem jantung dari waktu ke waktu. Ini memungkinkan kita untuk melihat pola *non-linier (chaotic, periodik, limit cycle, dll)* yang tidak bisa ditangkap oleh analisis *time series* konvensional.

## II. KAJIAN TEORI

Menyajikan dan menjelaskan teori-teori yang berkaitan dengan variabel-variabel penelitian. Poin subjudul ditulis dalam abjad.

### A. Coronary Artery Disease (*CAD*)

Penyakit arteri koroner adalah kondisi di mana terdapat pasokan darah dan oksigen yang tidak memadai ke miokardium. Penyakit ini merupakan kondisi jantung umum yang melibatkan pembentukan plak aterosklerotik di lumen pembuluh darah. Hal ini menyebabkan gangguan aliran darah dan dengan demikian pengiriman oksigen ke miokardium. Arteri koroner merupakan pembuluh darah pertama yang bercabang dari aorta, dan menyediakan pasokan oksigen dan nutrisi penting bagi lapisan-lapisan jantung[7].

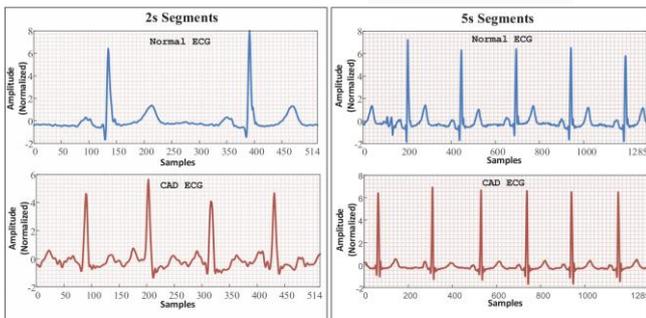


GAMBAR 1. Anatomi arteri koroner.

Anatomi dari arteri koroner meliputi arteri koroner kanan, arteri koroner utama kiri, arteri desenden anterior kiri, dan arteri sirkumfleksi kiri, adalah empat arteri koroner utama[8]. Penyumbatan arteri ini merupakan penyebab umum angina, penyakit jantung, serangan jantung, dan gagal jantung. Kondisi ini bisa bersifat kronis, yaitu penyempitan arteri koroner secara bertahap dari waktu ke waktu, sehingga mengurangi pasokan darah ke bagian otot. Atau bisa juga bersifat akut, yang diakibatkan oleh pecahnya plak secara tiba-tiba dan terbentuknya bekuan darah[8]. Pemeriksaan CAD harus invasif, cepat, dan mudah digunakan untuk klinis.

Karakteristik waktu dan frekuensi gelombang P, kompleks QRS, dan gelombang T pada individu sehat berbeda dengan yang memiliki CAD. Pada sinyal EKG normal, puncak R dan gelombang T lebih stabil, namun lebih rendah pada sinyal CAD[9]. Sinyal EKG normal memiliki R-peak yang terlihat jelas, sedangkan pada sinyal CAD hanya sedikit segmen R-peak dengan amplitudo tinggi yang terdeteksi. Perubahan karakteristik gelombang EKG, seperti:

- Depresi segmen ST
- Inversi gelombang T
- Gelombang Q patologis
- Penurunan variabilitas RR interval



GAMBAR 2. Perbedaan Sinyal EKG CAD dan Normal

Perubahan tersebut dapat muncul secara subklinis (tanpa gejala nyata) dan hanya terlihat melalui analisis mendalam sinyal EKG.

## B. Heart Rate Variability (HRV)

Heart Rate Variability (HRV), didefinisikan sebagai perubahan interval waktu antara detak jantung yang berdekatan, dianggap sebagai ukuran fungsi neurokardiak yang mencerminkan interaksi jantung-otak dan proses sistem saraf otonom non-linier yang dinamis[10]. Analisis HRV, yang merupakan turunan dari sinyal EKG, memungkinkan deteksi gangguan otonom yang berkaitan dengan CAD, bahkan pada tahap awal. HRV dan denyut jantung merupakan

dua indikator yang berbeda, dimana denyut jantung dihitung dengan menghitung detak jantung dalam satu menit sementara HRV berubah seiring waktu ketika satu detak jantung direkam[11]. Banyak faktor seperti usia, jenis kelamin, kebugaran, merokok, stres, atau pengobatan dapat memengaruhi HRV. Oleh karena itu, nilai normal bervariasi secara signifikan di antara individu.

Beberapa tahun terakhir, beberapa penelitian telah menguji validitas dan reabilitas rekaman *ultra-short-term* HRV (UST-HRV). UST-HRV adalah teknik untuk mengukur HRV dalam periode singkat, biasanya kurang dari 5 menit yang dapat digunakan untuk memantau variasi HRV dari waktu ke waktu dan memberikan informasi penting mengenai sistem saraf otonom[12]. Ada dua metode utama untuk menghitung HRV yaitu domain waktu dan domain frekuensi. Metode domain waktu mengukur jumlah HRV berdasarkan *interbeat intervals* (IBI) dan menghasilkan parameter seperti *Standar Deviation of interval R-R* (SDRR) dan *Root Mean Square of Successive Differences* (RMSSD)[13].

Standar deviasi interval RR (SDRR) dihitung sebagai[14]:

$$SDRR = \langle \overline{RR_i^2} \rangle^{1/2} \quad (1)$$

Deret waktu RR berisi istilah konstan  $\langle RR \rangle$  dan istilah berfluktuasi  $\hat{RR}$ . Tanda kurung siku mewakili nilai rata-rata. RMSSD mencerminkan variansi detak jantung dari satu detak ke detak lainnya dan merupakan ukuran domain waktu utama yang digunakan untuk menilai perubahan yang tercermin dalam HRV dan mewakili variabilitas jangka pendek antara  $RR_i$ [15]. RMSSD dihitung sebagai[14]:

$$RMSSD = \langle (\Delta RR_i)^2 \rangle^{1/2} \quad (1)$$

dimana  $\Delta RR_i$  adalah perbedaan antara interval RR yang berurutan  $\Delta RR$ .

## C. Attractors

*Attractors* adalah konsep dalam teori sistem dinamis dan analisis non-linier yang digunakan untuk menggambarkan keadaan atau pola tertentu yang stabil dan di mana sebuah sistem cenderung "berkumpul" setelah menjalani evolusi. *Attractors* adalah entitas geometris yang mengkarakterisasi perilaku jangka panjang suatu sistem dan dapat berbentuk *fixed point*, *limit cycle*, atau *strange attractors*[16].

Karena deskripsi matematis dan fase sistem dinamik alami seringkali tidak diketahui, rekonstruksi ruang fase diperlukan. *Phase space reconstruction* (PSR) ini menggunakan lebih dari satu sinyal dari sistem sebagai fungsi waktu, lalu deret waktu tersebut membangun representasi tidak langsung dari keadaan yang diamati[6]. Metode populer untuk rekonstruksi ruang keadaan adalah metode *delays*[17]. Menggunakan metode ini berarti menentukan nilai waktu tunda  $\tau$  dan dimensi *embedding*  $m$ . Waktu tunda (*delay*) dalam rekonstruksi ruang fase mengacu pada interval waktu pada pengamatan berurutan dari deret waktu, sedangkan dimensi *embedding* menunjukkan jumlah variabel yang digunakan untuk karakterisasi *attractors*[16]. Dengan bilangan bulat positif dimensi- $p$  dan *delay* waktu  $\tau$ , deret waktu tersebut tertanam dalam ruang berdimensi- $p$ , sehingga:

$$\vec{y}(t) = (x(t), x(t+\tau), x(t+2\tau), \dots, x(t+(d-1)\tau)) \quad (2)$$

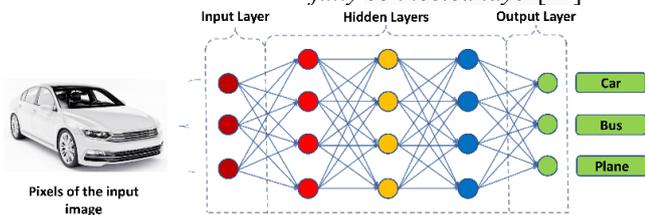
di mana  $x(t)$  menunjukkan observasi pada waktu  $t$ ,  $\tau$  adalah *delay* waktu, dan  $d$  adalah dimensi *embedding*[18].

#### D. Uji Kolmogorov-Smirnov Dua Sampel

Uji Kolmogorov-Smirnov (KS *test*) dua sampel beroperasi dengan mengukur jarak antara fungsi distribusi empiris yang berasal dari dua sampel data yang berbeda[19]. Berbeda dengan uji Kolmogorov-Smirnov satu sampel yang digunakan untuk menguji kesesuaian data terhadap distribusi teoretis, uji dua sampel mengukur sejauh mana dua sampel independen memiliki bentuk distribusi yang serupa. Karena bersifat nonparametrik, uji ini tidak membuat asumsi apa pun terkait distribusi yang mendasari pengambilan sampel. Namun, seperti kebanyakan uji statistik yang umum digunakan, ada asumsi yang mendasari bahwa nilai-nilai dalam setiap sampel adalah independen secara statistik[19].

#### E. Convolutional Neural Network (CNN)

CNN atau *Convolutional Neural Network* adalah sejenis jaringan saraf *feedforward* yang mampu mengekstraksi fitur dari data dengan struktur konvolusi[20]. CNN adalah sistem kecerdasan buatan yang berbasis pada jaringan saraf berlapis yang dapat mengidentifikasi, mengenali, dan mengklasifikasikan objek serta mendeteksi dan mengelompokkan objek dalam gambar[21]. Berbeda dari metode ekstraksi fitur tradisional, CNN tidak perlu mengekstraksi fitur secara manual. Gambar diproses terlebih dahulu kemudian dimasukkan ke dalam jaringan melalui *input layer*, diproses oleh beberapa *convolutional layer* dan *pooling layer* yang disusun secara bergantian, kemudian diklasifikasikan berdasarkan *fully connected layer*[22].



GAMBAR 4. Ilustrasi jaringan CNN

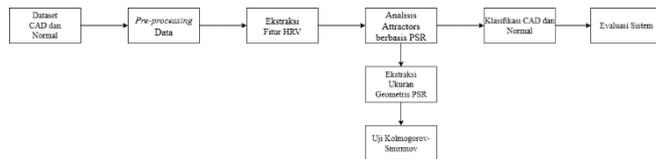
CNN terdiri dari dua buah komponen, yaitu lapisan ekstraksi fitur dan lapisan identifikasi. Lapisan ekstraksi fitur terdiri dari lapisan konvolusi, fungsi aktivasi *Rectified Linear Units* (ReLU) dan *Pooling*. Pada lapisan identifikasi terdiri dari proses *Flatten*, *Fully-Connected Layer* dan *Softmax*[23]. CNN bekerja seperti mata dengan melihat kondisi sesaat tanpa mengingat informasi sebelumnya sehingga banyak digunakan dalam pengolahan gambar, kata, video maupun *time series* dengan menyesuaikan dimensi operasi konvolusi.

### III. METODE

Bab ini menjelaskan secara rinci pendekatan, metode, dan langkah-langkah yang digunakan dalam penelitian untuk menjawab pertanyaan penelitian dan mencapai tujuan yang telah ditetapkan.

#### A. Desain Sistem

Desain sistem pada penelitian ini bertujuan untuk membangun sebuah alur kerja yang terstruktur dalam mengklasifikasikan kondisi jantung normal dan CAD berdasarkan analisis gambar PSR yang berasal dari ekstraksi fitur HRV.



GAMBAR 3. Diagram blok sistem

Diagram blok sistem ini diawali dengan akuisisi sinyal EKG dari dataset. Sinyal tersebut selanjutnya akan melalui tahap *pre-processing*, yang kemudian akan memasuki tahap ekstraksi fitur HRV yang akan digunakan untuk analisis *attractors* berbasis PSR. Gambar PSR kemudian akan melalui tahap ekstraksi ukuran geometris PSR untuk keperluan analisis distribusi data dan uji Kolmogorov-Smirnov dua sampel untuk mengetahui bahwa kedua data tidak berasal dari distribusi yang sama. Gambar PSR yang dihasilkan juga digunakan sebagai input untuk model CNN. Model CNN dikembangkan untuk belajar membedakan pola *attractors* PSR antara kondisi normal dan CAD, dengan pelatihan menggunakan dataset gambar yang telah dibagi berdasarkan kelas, *lead* EKG, dan *delay*. Tahap akhir yaitu evaluasi sistem dengan beberapa *matrix* evaluasi.

#### 1) Dataset

Penelitian ini melibatkan penggunaan data rekaman EKG *12-lead* dari *St Petersburg Incart 12-lead Arrhythmia Database*[24]. Rekaman tersebut terdiri dari 75 rekaman beranotasi yang diekstrak dari 32 rekaman Holter. Rekaman yang akan diolah hanya rekaman dengan diagnosis CAD yang berjumlah 7 rekaman. Setiap rekaman berdurasi 30 menit dengan *sampling rate* 257 Hz[24]. Sinyal EKG pada rekaman ini memiliki 12 sadapan. Namun untuk kebutuhan penelitian, *lead* EKG yang akan digunakan hanya *lead II* dan *V1*.

Data EKG normal merupakan basis data aritmia MIT-BIH *Arrhythmia Database* yang terdiri dari 48 cuplikan rekaman EKG ambulatori dua saluran yang berdurasi 30 menit[25]. Basis data tersebut diperoleh dari 47 subjek yang diteliti oleh laboratorium Aritmia BIH pada tahun 1975 dan 1979. Rekaman tersebut didigitalkan pada 360 sampel per detik per saluran dengan resolusi 11-bit pada rentang 10 mV[25]. Untuk penelitian ini, rekaman yang diambil hanya 7 rekaman EKG normal dengan *lead* MLII dan *V1*.

#### 2) Pre-processing

Sinyal EKG yang diperoleh dari basis data memiliki frekuensi *sampling* bervariasi, tergantung pada perangkat perekam dan sumber data. Untuk menyamakan skala waktu antar sinyal dan memastikan konsistensi dalam analisis berikutnya, dilakukan proses penyesuaian *sampling rate* terhadap kedua sinyal EKG (CAD dan normal). Langkah ini dilakukan untuk memastikan bahwa sinyal memiliki frekuensi pengambilan sampel yang konsisten dengan kebutuhan analisis atau model. Teknik yang dilakukan adalah *upsampling* pada dataset *St Petersburg Incart 12-lead Arrhythmia Database* yang semula 257 Hz menjadi 360 Hz.

Karena adanya keterbatasan dataset CAD pada *St Petersburg Incart 12-lead Arrhythmia Database* yang hanya berjumlah 7 rekaman, maka dilakukan segmentasi sinyal. Sinyal dibagi menjadi 4 segmen dengan masing-masing segmen berdurasi 450 detik. Pemilihan durasi 450 detik dilakukan dengan mempertimbangkan keseimbangan antara panjang sinyal (durasi total 1800 detik). Segmentasi dilakukan pada 7 rekaman dataset CAD *St Petersburg Incart 12-lead Arrhythmia Database* dan 7 rekaman dataset normal MIT-BIH *Arrhythmia Database*.

Deteksi R-peak dilakukan pada sinyal EKG yang telah mengalami proses *upsampling* dan *filtering*. Sinyal difilter menggunakan *band-pass filter Butterworth* orde 4 dengan batas bawah 0.5 Hz dan batas atas 40 Hz, untuk menghilangkan *noise* frekuensi rendah (seperti *baseline drift*) dan *noise* frekuensi tinggi (seperti gangguan otot).

### 3) Ekstraksi Fitur HRV

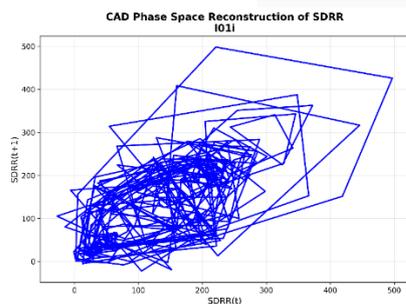
Ekstraksi fitur HRV dalam penelitian ini dilakukan berdasarkan segmen *ultra short-term*. Dalam penelitian ini, sinyal EKG dibagi menjadi segmen-segmen menggunakan pendekatan *sliding window*, yaitu dengan menentukan:

- Panjang segmen (*window length*): yaitu durasi tiap potongan sinyal EKG yang akan dianalisis, ditetapkan selama 10, 20, dan 30 detik.
- Langkah pergeseran (*step size*): yaitu selang waktu pergeseran antar segmen, ditetapkan sebesar 1-5 detik, yang dapat mengakibatkan segmen saling tumpang tindih (*overlapping*) jika  $step\ size < window\ length$ .

Setiap segmen kemudian diproses untuk mendeteksi puncak R (*R-peak*), dimana diperoleh deret waktu RR interval (RRi). Nilai-nilai HRV diekstraksi dari RRi tersebut menggunakan berbagai parameter *time-domain*, yaitu SDRR dan RMSSD.

### 4) Analisis Attractors

Analisis *attractors* dilakukan dengan *phase space reconstruction* (PSR). PSR dilakukan dengan memanfaatkan teknik *embedding* berdasarkan *delay* ( $\tau$ ) dan dimensi *embedding* ( $m$ ). *Delay* menentukan seberapa jauh data waktu digeser untuk membentuk koordinat baru, sedangkan dimensi *embedding* adalah jumlah sumbu ruang fase. Rekonstruksi dilakukan menggunakan metode *delay-coordinate embedding* dua dimensi, yaitu dengan membentuk pasangan titik ( $x(t)$ ,  $x(t+\tau)$ ), di mana  $\tau$  dibagi menjadi 3 variasi, yaitu +1, +5, dan +10, sedangkan untuk dimensi *embedding* menggunakan PSR 2 dimensi.



GAMBAR 5. Ilustrasi PSR ( $x(t)$ ,  $x(t+\tau)$ )

### 5) Ekstraksi Geometris Ukuran PSR

Setelah melakukan rekonstruksi ruang fase, setiap gambar PSR dianalisis untuk menghitung nilai diameter, yaitu jarak maksimum antar titik dalam ruang dua dimensi. Nilai-nilai diameter yang diperoleh dari setiap gambar kemudian digunakan untuk menyusun distribusi data, baik untuk kelas normal maupun kelas CAD. Dalam penelitian ini, estimasi diameter dari pola PSR dilakukan menggunakan pendekatan berbasis PCA. Metode ini dipilih karena kemampuannya dalam mengidentifikasi arah utama

penyebaran data (*principal axis*) secara statistik, sehingga memberikan estimasi ukuran geometris yang lebih stabil terhadap variasi orientasi maupun bentuk citra PSR. PCA digunakan untuk menentukan arah utama sebaran pola *attractors*. Selanjutnya, semua titik pada *attractors* diproyeksikan ke sumbu utama tersebut, dan diameter dihitung sebagai selisih maksimum proyeksi.

### 6) Uji Kolmogorov-Smirnov Dua Sampel

Uji statistik yang digunakan adalah Kolmogorov-Smirnov test (K-S test) dua sampel. Nilai *p-value* yang diperoleh dari pengujian ini akan menjadi dasar interpretasi untuk menentukan apakah kedua kelas berasal dari distribusi yang sama, di mana:

- Jika  $p\text{-value} < 0.05$ , maka terdapat perbedaan signifikan antara distribusi diameter PSR pada kedua kelas.
- Jika  $p\text{-value} \geq 0.05$ , maka tidak terdapat perbedaan distribusi yang signifikan.

Penggunaan uji tipe Kolmogorov-Smirnov dalam uji normalitas adalah karena nilai sampel  $> 50$  sedangkan uji tipe Shapiro-Wilk digunakan dalam uji normalitas apabila nilai sampel  $< 50$ .

### 7) Klasifikasi

Pada tahap pre-processing, seluruh citra diubah menjadi ukuran  $224 \times 224$  piksel sesuai standar input arsitektur VGG-16 ( $224 \times 224 \times 3$ ) agar kompatibel dengan bobot *pre-trained* ImageNet. Fitur diekstraksi melalui 13 lapisan konvolusi dan *5 max pooling*, menghasilkan tensor  $7 \times 7 \times 512$  yang kemudian direduksi menjadi vektor 512 dimensi menggunakan *GlobalAveragePooling2D* untuk mengurangi parameter dan risiko *overfitting*. Arsitektur dilanjutkan dengan dua lapisan *Dense* berukuran 256 neuron yang masing-masing diikuti *Dropout* (0,5). Lapisan output *Dense* berisi 2 neuron (Normal, CAD) dengan aktivasi *softmax*. Pelatihan menggunakan *loss function* *sparse\_categorical\_crossentropy* karena label berupa bilangan bulat.

Sebagai bagian dari evaluasi sistem, penelitian ini tidak hanya menggunakan arsitektur CNN kompleks seperti VGG-16, tetapi juga menguji kinerja model klasifikasi yang lebih ringan dan sederhana, yaitu LeNet. Arsitektur LeNet yang digunakan menerima input citra PSR berukuran  $224 \times 224 \times 3$ , terdiri dari dua lapisan *Conv2D* (6 dan 16 filter, kernel  $5 \times 5$ , aktivasi ReLU) yang masing-masing diikuti *AveragePooling2D*, lalu *Flatten* dan tiga lapisan *Dense* (120, 84, dan 1 neuron). *Dropout* (0,3) diterapkan setelah *Dense* pertama untuk mencegah *overfitting*. Lapisan output menggunakan aktivasi sigmoid untuk klasifikasi biner (Normal/CAD). Model dikompilasi dengan *loss* *binary\_crossentropy* sesuai struktur output tunggal berbasis probabilitas.

#### B. Metode Pengujian

Pengujian dilakukan dengan membagi dataset gambar PSR menjadi dua kelas (Normal dan CAD), yang berasal dari rekonstruksi dua fitur HRV (SDRR, RMSSD), dua lead EKG (II/MLII, V1), dan tiga nilai *delay embedding* (+1, +5, +10). Setiap kombinasi diuji secara terpisah untuk menilai performa klasifikasi. Sebagai pelengkap, uji Kolmogorov-Smirnov dua

sampel diterapkan pada nilai diameter *attractor* PSR untuk memverifikasi perbedaan distribusi geometris antar kelas. Model dievaluasi menggunakan metrik akurasi, presisi, sensitivitas, spesifisitas, *confusion matrix*, dan kurva ROC-AUC pada data validasi. Perbandingan performa juga dilakukan antar kombinasi fitur, lead, delay, serta antara arsitektur VGG-16 dan LeNet.

#### IV. HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil dari rangkaian proses pengujian yang telah dilakukan berdasarkan metode yang dijelaskan pada bab 3.

##### A. Hasil Ekstraksi Fitur HRV

Ekstraksi fitur *time-domain* HRV untuk setiap segmen rekaman dengan metode *windowed* yaitu *window size* 10, 20, dan 30 detik serta *step size* 1-5 detik dilakukan pada kedua *lead* sehingga total HRV *value* yang dihasilkan untuk rekonstruksi ruang fase adalah:

- 1) 420 file HRV *value* dari SDRR *Lead* II CAD
- 2) 420 file HRV *value* dari SDRR *Lead* II Normal
- 3) 420 file HRV *value* dari SDRR *Lead* V1 CAD
- 4) 420 file HRV *value* dari SDRR *Lead* V1 Normal
- 5) 420 file HRV *value* dari RMSSD *Lead* II CAD
- 6) 420 file HRV *value* dari RMSSD *Lead* II Normal
- 7) 420 file HRV *value* dari RMSSD *Lead* V1 CAD
- 8) 420 file HRV *value* dari RMSSD *Lead* V1 Normal

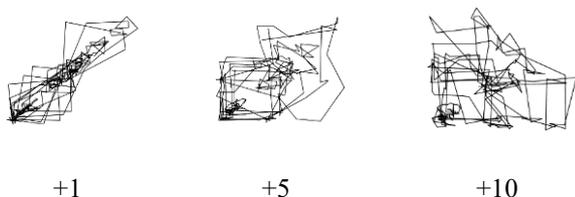
Dimana 420 diperoleh dari hasil *windowed* pada 28 segmen, yaitu dengan *sliding window* 3 variasi dan *step size* 5 variasi.

##### B. Phase Space Reconstruction (PSR)

Hasil dari ekstraksi fitur HRV yang sebelumnya dilakukan kemudian diolah menjadi PSR 2 dimensi. Sehingga total PSR yang dihasilkan adalah:

- 1) 420 gambar PSR SDRR *Lead* II CAD
- 2) 420 gambar PSR SDRR *Lead* II Normal
- 3) 420 gambar PSR SDRR *Lead* V1 CAD
- 4) 20 gambar PSR SDRR *Lead* V1 Normal
- 5) 420 gambar PSR RMSSD *Lead* II CAD
- 6) 420 gambar PSR RMSSD *Lead* II Normal
- 7) 420 gambar PSR RMSSD *Lead* V1 CAD
- 8) 420 gambar PSR RMSSD *Lead* V1 Normal

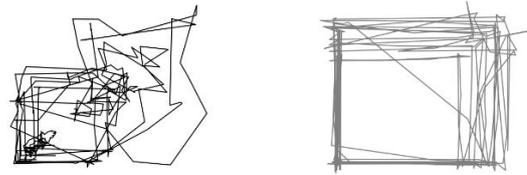
Gambar yang dihasilkan berdimensi 600 x 500. Perbandingan hasil PSR dari fitur SDRR dengan *delay* +1, +5, dan +10 pada Gambar 6.



GAMBAR 6. Perbedaan PSR delay +1, +5, dan +10

PSR kelas CAD menunjukkan kontur yang tidak teratur, bersifat acak, dan tidak simetris. Ini menunjukkan bahwa sistem dinamika jantungnya tidak memiliki keteraturan yang jelas. Sebaliknya, PSR subjek normal memperlihatkan pola

kontur yang cukup rapi dan membentuk struktur geometris menyerupai segi empat, mencerminkan keteraturan sistem.



GAMBAR 7. Perbedaan PSR CAD dan Normal

PSR CAD mengandung banyak *loop* yang saling bertumpuk dan silang, tanpa adanya satu pola dominan. Hal ini merupakan karakteristik dari *strange attractor*. Di sisi lain, PSR normal memiliki satu bentuk *loop* yang mendominasi, yakni pola kotak yang berulang, mendekati karakteristik *limit cycle*. Namun, hal ini berbeda dengan yang terjadi pada *lead* V1. Pada *lead* V1, hasil PSR normal cenderung mendekati *strange attractors*. *Lead* V1 terletak di dekat atrium kanan dan sering menangkap aktivitas atrium, serta gangguan atrium seperti fibrilasi atau *flutter*[26]. Ritme atrium secara alami kurang periodik dibandingkan aktivitas ventrikel pada *lead* II. Karakteristik sinyal ini dapat menyebabkan PSR dari V1 tampak lebih kompleks atau *chaotic*, bahkan pada subjek normal.

##### C. Uji Kolmogorov-Smirnov Dua Sampel

Data yang digunakan dalam pengujian ini merupakan nilai diameter yang diperoleh dari hasil ekstraksi ukuran geometris PSR.

TABEL 1. Rekapitulasi hasil uji Kolmogorov-smirnov dua sampel

Fitur	Lead	Delay	KS D-Stat	p-value	Kesimpulan
SDRR	II	+1	0.1048	0.019854	Signifikan
SDRR	V1	+1	0.0619	0.39715	Tidak signifikan
RMSSD	II	+1	0.1833	$1.3895 \times 10^{-6}$	Signifikan
RMSSD	V1	+1	0.0524	0.61251	Tidak signifikan
SDRR	II	+5	0.1357	$8.6118 \times 10^{-4}$	Signifikan
SDRR	V1	+5	0.1714	$8.3272 \times 10^{-6}$	Signifikan
RMSSD	II	+5	0.1548	$8.3154 \times 10^{-5}$	Signifikan
RMSSD	V1	+5	0.2095	$1.7521 \times 10^{-8}$	Signifikan
SDRR	II	+10	0.2357	$1.2102 \times 10^{-10}$	Signifikan
SDRR	V1	+10	0.2690	$8.9054 \times 10^{-14}$	Signifikan
RMSSD	II	+10	0.2690	$8.9054 \times 10^{-14}$	Signifikan
RMSSD	V1	+10	0.2833	$2.9767 \times 10^{-15}$	Signifikan

Distribusi pada kelas CAD cenderung memiliki diameter yang lebih kecil dan lebih sempit, sementara kelas normal menunjukkan distribusi yang lebih lebar dan terdistribusi ke nilai diameter yang lebih tinggi. Hal ini mencerminkan

penurunan kompleksitas dan variabilitas sistem fisiologis pada pasien CAD, yang ditangkap dengan baik melalui pendekatan PSR.

#### D. Hasil dan Analisis Klasifikasi Menggunakan VGG-16

Secara umum, VGG-16 menunjukkan performa yang unggul dalam hampir seluruh konfigurasi, terutama pada PSR yang berasal dari lead II. Kombinasi terbaik diperoleh pada fitur RMSSD dengan *delay* +1 pada *lead* II, yang menghasilkan akurasi sebesar 99%, sensitivitas 1,00, spesifisitas 0,9881, dan AUC 1,00. Hal ini menunjukkan bahwa VGG-16 mampu mengenali pola pada gambar PSR dengan sangat baik.

TABEL 2. Rekapitulasi hasil klasifikasi VGG-16

Delay	Lead	Fitur HRV	Akurasi (%)	Persisi	Sensitivitas	Spesifisitas	AUC
+1	II	SDR R	95	0,9524	0,9524	0,9524	0,9908
	V1	SDR R	73	0,7619	0,6905	0,6905	0,8068
	II	RMSSD	99	1,00	1,00	0,9881	1,0000
	V1	RMS SD	69	0,7262	0,6548	0,6548	0,7537
+5	II	SDR R	98	0,9643	0,9643	0,9881	0,9986
	V1	SDR R	79	0,8333	0,7381	0,7381	0,8330
	II	RMS SD	95	0,9405	0,9524	0,9524	0,9823
	V1	RMS SD	75	0,8571	0,6429	0,6429	0,7834
+10	II	SDR R	98	0,9643	1,00	0,9643	0,9996
	V1	SDR R	74	0,8571	0,6310	0,6310	0,7880
	II	RMS SD	98	0,9881	0,9643	0,9643	0,9984
	V1	RMS SD	74	0,9167	0,5714	0,5714	0,8108

Namun demikian, performa VGG-16 relatif menurun ketika digunakan pada *lead* V1, baik untuk SDRR maupun RMSSD, dengan akurasi berkisar antara 69% hingga 75%, serta AUC yang lebih rendah (0,7537–0,8068). Hal ini mengindikasikan bahwa *lead* II lebih informatif secara visual-spasial dalam mendeskripsikan dinamika HRV dibandingkan *lead* V1, khususnya untuk deteksi CAD berbasis PSR.

#### E. Hasil dan Analisis Hasil dan Analisis Klasifikasi Menggunakan LeNet

Sementara itu, LeNet menunjukkan performa yang cukup kompetitif, meskipun secara umum lebih rendah dibandingkan VGG-16. Kombinasi terbaik LeNet diperoleh pada fitur RMSSD dengan *delay* +10 pada *lead* II, yang mencapai akurasi 98,21% dan AUC 0,9984, mendekati performa tertinggi dari VGG-16. Hal ini menunjukkan bahwa meskipun lebih sederhana, LeNet tetap mampu melakukan klasifikasi secara efektif pada citra PSR yang memiliki kontras spasial yang jelas.

TABEL 3. Rekapitulasi hasil klasifikasi LeNet

Delay	Lead	Fitur HRV	Akurasi (%)	Persisi	Sensitivitas	Spesifisitas	AUC
+1	II	SDR R	91,67	0,8723	0,9762	0,8571	0,9847
	V1	SDR R	72,02	0,6796	0,8333	0,6071	0,7677
	II	RMSSD	96,43	0,9756	0,9524	0,9762	0,9712
	V1	RMS SD	73,21	0,6893	0,8452	0,6190	0,8010
+5	II	SDR R	91,07	0,8791	0,9524	0,8690	0,9596
	V1	SDR R	70,24	0,6932	0,7262	0,6786	0,8016
	II	RMSSD	91,07	0,9259	0,8929	0,9286	0,9546
	V1	RMS SD	72,62	0,6827	0,8452	0,6071	0,8087
+10	II	SDR R	90,49	0,9250	0,8810	0,9286	0,9592
	V1	SDR R	73,21	0,7143	0,7738	0,6905	0,8017
	II	RMSSD	98,21	0,9880	0,9762	0,9881	0,9984
	V1	RMS SD	69,64	0,6486	0,8571	0,5357	0,7517

Namun, pada kombinasi *lead* V1, performa LeNet mengalami penurunan yang signifikan, dengan akurasi terendah pada RMSSD *delay* +10 (69,64%) dan AUC hanya 0,7517.

Secara komparatif, VGG-16 konsisten memberikan hasil yang lebih baik dalam hal akurasi, AUC, dan keseimbangan antara sensitivitas dan spesifisitas, terutama pada *lead* II. LeNet unggul dari sisi efisiensi komputasi, namun menunjukkan keterbatasan dalam mengekstraksi fitur kompleks dari citra PSR dengan *noise* atau struktur *chaotic* yang tidak terlalu kontras. Kinerja keduanya menurun pada *lead* V1, yang mengindikasikan bahwa sinyal dari *lead* tersebut kurang representatif untuk menghasilkan citra PSR yang mudah dibedakan antara kondisi normal dan CAD.

## V. KESIMPULAN

Penelitian ini mengusulkan metode klasifikasi CAD berbasis rekonstruksi ruang fase dari fitur HRV (SDRR dan RMSSD) hasil sinyal EKG. Pola *attractor* dari PSR diklasifikasikan menggunakan CNN arsitektur VGG-16 dan LeNet. Hasil pengujian menunjukkan: (1) *Attractor* PSR membedakan dinamika jantung antara CAD dan normal; (2) Uji Kolmogorov–Smirnov dua sampel mengonfirmasi perbedaan signifikan distribusi diameter PSR antar kelas; (3) CNN pada citra PSR memberikan akurasi dan sensitivitas tinggi; (4) *Lead* II lebih informatif dibanding V1; (5) Kombinasi *lead*, fitur HRV, dan variasi *delay* meningkatkan performa klasifikasi. VGG-16 mencapai akurasi, sensitivitas, dan spesifisitas tinggi, sehingga metode ini berpotensi dikembangkan sebagai sistem deteksi dini CAD yang cepat, non-invasif, dan efektif.

## REFERENSI

- [1] World Health Organization (WHO), "Cardiovascular diseases (CVDs)," World Health Organization (WHO). Accessed: Jun. 19, 2025. [Online]. Available: [https://www.who.int/news-room/factsheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/factsheets/detail/cardiovascular-diseases-(cvds))
- [2] S. Benjamin, J. Catherine, and R. G. Andrew, "GLOBAL PREVALENCE OF CORONARY ARTERY DISEASE: AN UPDATE FROM THE GLOBAL BURDEN OF DISEASE STUDY," *J Am Coll Cardiol*, vol. 83, no. 13 Supplement, p. 2320, Apr. 2024, doi: 10.1016/S0735-1097(24)04310-9.
- [3] Erdania, M Faizal KGS., and Angraini Berti Rima, "FAKTOR – FAKTOR YANG BERHUBUNGAN DENGAN KEJADIAN PENYAKIT JANTUNG KORONER (PJK) DI RSUD DR. (H.C.) IR. SOEKARNO PROVINSI BANGKA BELITUNG," Jun. 2023, doi: <https://doi.org/10.47560/kep.v12i1.472>.
- [4] B. B. Purkayastha, A. Hazarika, A. Thomas, and S. Poddar, "Cardiac Anomaly Detection using Embedded Attractors Reconstructed from Multichannel ECG," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Nov. 2022, pp. 120–126. doi: 10.1145/3574198.3574217.
- [5] K. Li, C. Cardoso, A. Moctezuma-Ramirez, A. Elgalad, and E. Perin, "Heart Rate Variability Measurement through a Smart Wearable Device: Another Breakthrough for Personal Health Monitoring?," Dec. 01, 2023, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/ijerph20247146.
- [6] S. K. Nayak, A. Bit, A. Dey, B. Mohapatra, and K. Pal, "A review on the nonlinear dynamical system analysis of electrocardiogram signal," 2018, *Hindawi Limited*. doi: 10.1155/2018/6920420.
- [7] A. Saxton, R. Chaudhry, and B. Manna, *Anatomy, Thorax, Heart Right Coronary Arteries*. StatPearls, 2023.
- [8] American Heart Association, "Coronary Artery Disease - Coronary Heart Disease," American Heart Association. Accessed: Jul. 02, 2025. [Online]. Available: <https://www.heart.org/en/health-topics/consumer-healthcare/what-is-cardiovascular-disease/coronary-artery-disease>
- [9] E. Butun, O. Yildirim, M. Talo, R. S. Tan, and U. Rajendra Acharya, "1D-CADCapsNet: One dimensional deep capsule networks for coronary artery disease detection using ECG signals," *Physica Medica*, vol. 70, pp. 39–48, Feb. 2020, doi: 10.1016/j.ejmp.2020.01.007.
- [10] M. Mohammadpoor Faskhodi, M. Fernández-Chimeno, and M. A. Garcia-González, "Arousal detection by using ultra-short-term heart rate variability (HRV) analysis," *Frontiers in Medical Engineering*, vol. 1, Aug. 2023, doi: 10.3389/fmede.2023.1209252.
- [11] R. Tiwari, R. Kumar, S. Malik, T. Raj, and P. Kumar, "Analysis of Heart Rate Variability and Implication of Different Factors on Heart Rate Variability," *Curr Cardiol Rev*, vol. 17, no. 5, Jan. 2021, doi: 10.2174/1573403x16999201231203854.
- [12] M. Mohammadpoor Faskhodi, M. Fernandez-Chimeno, and M. A. Garcia-Gonzalez, "Using Ultra-Short-Term Heart Rate Variability (HRV) Analysis to Track Posture Changes," *IEEE Access*, vol. 12, pp. 129994–130006, 2024, doi: 10.1109/ACCESS.2024.3424245.
- [13] T. Frippiat, C. van Beckhoven, E. Moysse, and T. Art, "Accuracy of a heart rate monitor for calculating heart rate variability parameters in exercising horses," *J Equine Vet Sci*, vol. 104, Sep. 2021, doi: 10.1016/j.jevs.2021.103716.
- [14] A. Natarajan, "Heart rate variability during mindful breathing meditation," *Front Physiol*, vol. 13, Jan. 2023, doi: 10.3389/fphys.2022.1017350.
- [15] J. C. Moses, S. Adibi, M. Angelova, and S. M. S. Islam, "Time-domain heart rate variability features for automatic congestive heart failure prediction," *ESC Heart Fail*, vol. 11, no. 1, pp. 378–389, Feb. 2024, doi: 10.1002/ehf2.14593.
- [16] A. Al Fahoum and A. Zyout, "Early detection of neurological abnormalities using a combined phase space reconstruction and deep learning approach," *Intell Based Med*, vol. 8, Jan. 2023, doi: 10.1016/j.ibmed.2023.100123.
- [17] M. Matilla-Garcia, I. Morales, J. M. Rodríguez, and M. R. Marín, "Selection of embedding dimension and delay time in phase space reconstruction via symbolic dynamics," *Entropy*, vol. 23, no. 2, pp. 1–13, Feb. 2021, doi: 10.3390/e23020221.
- [18] Y. L. Chen *et al.*, "High-dimensional phase space reconstruction with a convolutional neural network for structural health monitoring," *Sensors*, vol. 21, no. 10, May 2021, doi: 10.3390/s21103514.
- [19] J. R. Lanzante, "Testing for differences between two distributions in the presence of serial correlation using the Kolmogorov–Smirnov and Kuiper’s tests," *International Journal of Climatology*, vol. 41, no. 14, pp. 6314–6323, Nov. 2021, doi: 10.1002/joc.7196.
- [20] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of image classification algorithms based on convolutional neural networks," Nov. 01, 2021, *MDPI*. doi: 10.3390/rs13224712.
- [21] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions," Mar. 01, 2023, *MDPI*. doi: 10.3390/computation11030052.
- [22] L. Chen, S. Li, Q. Bai, J. Yang, S. Jiang, and Y. Miao, "Review of image classification algorithms based on convolutional neural networks," Nov. 01, 2021, *MDPI*. doi: 10.3390/rs13224712.
- [23] R. T. SENJAWATI, E. C. DJAMAL, and F. KASYIDI, "Identifikasi Emosi Melalui Sinyal EEG menggunakan 3D-Convolutional Neural Network," *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, vol. 12, no. 2, p. 417, Apr. 2024, doi: 10.26760/elkomika.v12i2.417.
- [24] E. Yakushenko, "St Petersburg INCART 12-lead Arrhythmia Database PhysioNet St. Petersburg Institute of Cardiological Technics 12-lead Arrhythmia Database (," May 2008, doi: 10.13026/C2V88N.
- [25] G. Moody and R. Mark, "MIT-BIH Arrhythmia Database," Feb. 2005, doi: 10.13026/C2F305.
- [26] H. Zhang *et al.*, "Atrial fibrillation classification based on the 2D representation of minimal subset ECG and a non-deep neural network," *Front Physiol*, vol. 14, 2023, doi: 10.3389/fphys.2023.1070621.