

Kombinasi Ekstraksi Ciri untuk Klasifikasi *Ventricular Fibrillation* menggunakan *Support Vector Machine*

<https://doi.org/10.28932/jste.v1i2.14024>

Received: 09 Desember 2025 | Revised: 29 Desember 2025 | Accepted: 30 Desember 2025

Creative Commons License 4.0 (CC BY – NC)



Raden Danisworo Rivianto Wicaksono^{#1}, Novie Theresia Br. Pasaribu^{✉#2}, Jo Suherman^{*3}

[#]*Program Studi Teknik Elektro, Fakultas Teknologi dan Rekayasa Cerdas, Universitas Kristen Maranatha
Jl. Prof. drg. Surya Sumantri No.65, Bandung, Jawa Barat 40164, Indonesia*

¹*danisrivianto@gmail.com*

²*novie.theresia@eng.maranatha.edu*

^{*}*Program Studi Pendidikan Dokter, Fakultas Kedokteran, Universitas Kristen Maranatha
Jl. Prof. drg. Surya Sumantri No.65, Bandung, Jawa Barat 40164, Indonesia*

³*jo.suherman@med.maranatha.edu*

[✉]Corresponding author: *novie.theresia@eng.maranatha.edu*

How to cite this article:

R. D. R. Wicaksono, N. T. B. Pasaribu, J. Suherman, “Kombinasi Ekstraksi Ciri untuk Klasifikasi *Ventricular Fibrillation* menggunakan *Support Vector Machine*,” *Journal of Smart Technology and Engineering*, vol. 1, no. 2, pp. 115–125, 2025, <https://doi.org/10.28932/jste.v1i2.14024>

Abstrak — *Ventricular Fibrillation* (VF) adalah kelainan ritme jantung yang mengancam jiwa yang ditandai oleh aktivitas listrik jantung yang tidak beraturan dan tidak terkoordinasi yang menyebabkan jantung dapat berhenti mendadak. *Electrocardiogram* (ECG) adalah tes medis untuk mendeteksi kelainan jantung dengan mengukur aktivitas listrik yang dihasilkan oleh jantung, saat jantung berkontraksi. ECG pada VF menunjukkan karakteristik yang sangat berbeda dari ritme jantung normal, dengan hilangnya gelombang P dan kompleks QRS yang teratur, digantikan oleh gelombang fibrilasi yang cepat, irregular, dan bervariasi dalam amplituda. *Support Vector Machine* (SVM) adalah salah satu jenis *Machine Learning*, pada dasarnya mencari hyperplane terbaik untuk memisahkan kelas. Kernel yang digunakan pada penelitian ini diperoleh yang terbaik dengan menggunakan *Quadratic Kernel*. Penelitian ini bertujuan untuk mendeteksi *Ventricular Fibrillation* (VF) atau Non-VF dari sinyal ECG menggunakan *Support Vector Machine* (SVM). *Preprocessing* pada penelitian ini: *window size* sinyal ECG (5 detik dan 10 detik), dilanjutkan dengan *High Pass Filter*, *Second Order Butterworth Low Pass Filter*, dan *Notch Filter*. Ekstraksi ciri yang digunakan adalah *Area Calculation* (pada penelitian ini mengusulkan menggunakan *Ratio Area*) dan *Spectral Analysis* (FSMN, A1, A2, A3). Kombinasi dari satu hingga kelima ekstraksi ciri tersebut dilatih dan diuji menggunakan SVM. Hasil yang diperoleh menunjukkan kombinasi tiga ekstraksi ciri: FSMN-A1-A2 mencapai performansi tertinggi dengan *accuracy* 97%, *sensitivity* 100%, *spesificity* 94% dan kombinasi ekstraksi ciri FSMN-A2-R. *Area* mencapai akurasi 97%, *sensitivity* 98%, *spesificity* 96%. Penambahan ekstraksi ciri dari tiga ke empat tidak meningkatkan performansi secara signifikan.

Kata Kunci — *Area Calculation*; ECG; *Spectral Analysis*; *Support Vector Machine*; *Ventricular Fibrillation*.

Combined Feature Extraction for Ventricular Fibrillation Classification Using Support Vector Machine

Abstract — *Ventricular Fibrillation (VF) is a life-threatening heart rhythm disorder characterised by irregular and uncoordinated electrical activity of the heart that causes the heart to stop suddenly. An Electrocardiogram (ECG) is a medical test that detects heart abnormalities by measuring the electrical activity of the heart during contraction. The ECG in the VF shows very different characteristics from the normal heart rhythm, with loss of P waves and a regular QRS complex, replaced by rapid, irregular, and variable fibrillation waves of variable amplitude. A Support Vector Machine (SVM) is a type of Machine Learning that seeks the best hyperplane to separate classes. The kernel used in this study is best obtained by using the Quadratic Kernel. This study aims to detect Ventricular Fibrillation (VF) or Non-VF from ECG signals using Support Vector Machine (SVM). Preprocessing in this study: window size of ECG signals (5 seconds and 10 seconds), followed by a High Pass Filter, a Second Order Butterworth Low Pass Filter, and a Notch Filter. The characteristics used for extraction are Area Calculation (in this study, proposes using Ratio Area) and Spectral Analysis (FSMN, A1, A2, A3). Combinations of one to five of these trait extracts were trained and tested using SVM. The results obtained showed a combination of three characteristic extractions: FSMN-A1-A2 achieved the highest performance with 97% accuracy, 100% sensitivity, 94% specificity and the FSMN-A2-R characteristic extraction combination. The Area achieves 97% accuracy, 98% sensitivity, and 96% specificity. Adding trait extraction from three to four did not significantly improve performance.*

Keywords — *Area Calculation; ECG; Spectral Analysis; Support Vector Machine; Ventricular Fibrillation.*

I. PENDAHULUAN

Ventricular Fibrillation (VF) adalah kelainan ritme jantung yang mengancam jiwa yang ditandai oleh aktivitas listrik jantung yang tidak beraturan dan tidak terkoordinasi yang menyebabkan jantung dapat berhenti mendadak [1], [2]. *Cardiovascular Diseases (CVDs)* atau penyakit kardiovaskular menjadi penyebab kematian utama di dunia dengan estimasi 17,5 juta kematian pada tahun 2012 dan diproyeksikan mencapai 23,6 juta pada tahun 2030 [3].

Electrocardiogram (ECG) adalah tes medis untuk mendeteksi kelainan jantung dengan mengukur aktivitas listrik yang dihasilkan oleh jantung, saat jantung berkontraksi. ECG dapat membantu mendiagnosis berbagai kondisi kesehatan seperti aritmia jantung, pembesaran jantung, peradangan jantung, dan penyakit jantung koroner. ECG pada VF menunjukkan karakteristik yang sangat berbeda dari ritme jantung normal, dengan hilangnya gelombang P dan kompleks QRS yang teratur, digantikan oleh gelombang fibrilasi yang cepat, irregular, dan bervariasi dalam amplituda [4]. Karakteristik spektral dari VF menjadikan *Spectral Analysis* sebagai pendekatan yang dianggap tepat untuk deteksi VF.

Parameter spektral yang umum digunakan termasuk *First Spectral Moment Normalized (FSMN)*, *Dominant Frequency (DF)*, *Spectral Energy Distribution (A1, A2, A3)*, dan *Amplitude Spectral Area (AMSA)*. Algoritma deteksi VF berbasis *Automated External Defibrillator (AED)* yang menggunakan parameter FSMN, A1, A2, dan A3 adalah algoritma *Spectral Algorithm (SPEC)*, yang dikembangkan oleh Barro, dkk. [5]. Algoritma SPEC bekerja di domain frekuensi dan menunjukkan kinerja yang baik, dengan nilai *sensitivity* 29.1% dan *specificity* 99.9% [5].

Support Vector Machine (SVM) telah banyak diaplikasikan untuk klasifikasi VF dengan hasil yang menjanjikan. Li, dkk. menggunakan SVM dengan algoritma genetika untuk seleksi ciri memilih kombinasi ciri yang optimal, pada proses validasi mencapai *accuracy* 96,3%, *sensitivity* 96,2%, dan *specificity* 96,2% pada deteksi VF dan *Ventricular Tachycardia (VT)* dengan *window size* 5 detik [6].

Alonso-Atienza, dkk. mengusulkan seleksi ciri menggunakan SVM dan *bootstrap methods* untuk deteksi VF, menggabungkan parameter temporal, spektral, dan *time-frequency* [7]. Penelitian ini menunjukkan bahwa kombinasi parameter dari *multiple domains* meningkatkan *detection efficiency* dibanding parameter tunggal. Dengan menggunakan tiga ekstraksi ciri terpilih (*RatioVar*, *QTL*, dan *Curve*), kinerja detektor VF dioptimalkan. Kumar, dkk. menggunakan *time-frequency* representation dan cubic SVM untuk klasifikasi VF, VT, dan NSR, mencapai *accuracy* 92,23% [16]. Pendekatan *Deep Learning (DL)* seperti CNN dan LSTM juga telah dikembangkan oleh Ruiz, dkk. mencapai *accuracy* di atas 95% tetapi proses yang memerlukan komputasi yang tinggi [8], [9].


Ekstraksi ciri yang tepat diperlukan dalam klasifikasi dengan menggunakan *Machine Learning (ML)* khususnya untuk klasifikasi VF. *Discrete Wavelet Transform (DWT)* sering digunakan untuk *multiresolution analysis*, memungkinkan dekomposisi sinyal ECG ke domain frekwensi [10]. *Fast Fourier Transform (FFT)* digunakan untuk *Spectral Analysis* dan estimasi *Spectral Power Density* [11]. Namun, penggunaan ekstraksi ciri yang banyak dapat menyebabkan *curse of dimensionality* dan *overfitting*.

Meskipun banyak penelitian berkenaan dengan deteksi VF menggunakan *Spectral Analysis* dan *Machine Learning*, terdapat beberapa celah yang bisa disolusikan. Pada penelitian ini bertujuan mengisi celah yang teridentifikasi melalui penelitian sistematis terhadap kombinasi ekstraksi ciri untuk klasifikasi VF/ Non-VF menggunakan *Support Vector Machine (SVM)*. Kontribusi utama penelitian ini meliputi: usulan ekstraksi ciri *Area Calculation* dengan menggunakan *Ratio Area* yang merupakan pengembangan dari ekstraksi ciri *Area*. Kemudian pada penelitian ini dilakukan eksplorasi secara sistematis, dengan mengevaluasi performansi *accuracy* dan *sensitivity* untuk klasifikasi VF/ Non-VF yang dimulai dari ekstraksi ciri tunggal hingga kombinasi lima ekstraksi ciri (1 hingga 5 ekstraksi ciri), total sebanyak 31 kombinasi yang berbeda.

II. METODE DAN MATERIAL

Pada Gambar 1 terlihat *block diagram* sistem klasifikasi *Ventricular Fibrillation* menggunakan *Support Vector Machine*. Input sinyal ECG yang diambil dari *PhysioBank ATM*, berasal dari *database: Creighton University Ventricular Tachyarrhythmia Database (CUIDB)* dan *Massachusetts Institute of Technology-Boston Beth Israel Hospital (MIT-BIH) Malignant Ventricular Arrhythmia Database (VFDB)* dengan jumlah data yang dipakai sebanyak 59 records.


Kemudian sinyal ECG dilakukan *Preprocessing* yang terdiri dari: *window size* sinyal ECG (5 detik dan 10 detik), *High Pass Filter*, *Second Order Low Pass Filter* dan *Notch Filter*. Setelah *Preprocessing* dilanjutkan ekstraksi ciri (*feature extraction*) dengan menggunakan *Area Calculation* dan *Spectral Analysis*. Classifier yang digunakan adalah *Support Vector Machine* untuk mengklasifikasikan *Ventricular Fibrillation (VF)* atau *Non-Ventricular Fibrillation*.



Gambar 1. Block Diagram Sistem Klasifikasi *Ventricular Fibrillation* menggunakan *Support Vector Machine*

A. ECG Signal

Electrocardiogram adalah tes non-invasif (yang tidak memerlukan sayatan tubuh) yang merekam aktivitas listrik pada jantung. Aktivitas listrik ini berhubungan dengan impuls yang bergerak dalam jantung yang menentukan detak dan irama jantung [12].



Gambar 2. Sinyal ECG [12]

Pada Gambar 2 adalah bagian dari Sinyal ECG [12]. Setiap siklus kontraksi dan relaksasi jantung dimulai oleh depolarisasi spontan pada nodus sinus, meskipun aktivitas ini tidak tampak pada rekaman EKG. Gelombang P merepresentasikan proses depolarisasi dan kontraksi atrium. Bagian awal gelombang P menggambarkan aktivitas atrium kanan, sedangkan bagian selanjutnya mencerminkan aktivitas atrium kiri. Ketika impuls listrik mencapai nodus AV, terjadi jeda singkat sehingga tidak ada aktivitas yang terekam pada ECG, yang dikenal sebagai segmen PR. Impuls depolarisasi kemudian merambat melalui sistem hantaran ventrikel. Area pertama yang mengalami depolarisasi adalah septum interventrikular. Depolarisasi ventrikel ini menghasilkan kompleks QRS. Gelombang T menggambarkan proses repolarisasi ventrikel. Repolarisasi atrium tidak tampak pada ECG. Beberapa segmen dan interval pada ECG, yaitu [12]:

- 1) *Interval PR*: menunjukkan waktu dari awal depolarisasi atrium hingga awal depolarisasi ventrikel.
- 2) *Segmen PR*: menunjukkan waktu dari akhir depolarisasi atrium hingga awal depolarisasi ventrikel.
- 3) *Segmen ST*: menggambarkan durasi dari akhir depolarisasi ventrikel hingga awal repolarisasi ventrikel.
- 4) *Interval QT*: menunjukkan waktu dari dimulainya depolarisasi ventrikel hingga berakhirnya repolarisasi ventrikel.
- 5) *Interval QRS*: menunjukkan durasi proses depolarisasi ventrikel.

B. Preprocessing


Kombinasi Ekstraksi Ciri untuk Klasifikasi *Ventricular Fibrillation* menggunakan *Support Vector Machine*

Raden Danisworo Rivianto Wicaksono, Novie Theresia Br. Pasaribu, Jo Suherman

Sebelum dilakukan *Preprocessing*, proses *window* (panjang sinyal) *size* dilakukan pada sinyal ECG durasi 1 jam dari 59 *records*, menjadi *window size* 5 detik dan 10 detik. Sehingga dihasilkan 100 *records* dengan panjang masing-masing *window size* (5 detik dan 10 detik), jumlah *records* VF sebanyak 50 data dan Non-VF sebanyak 50 data.

Preprocessing awal sinyal ECG diterapkan filter digital: *High Pass Filter* (filter yang berfungsi untuk melewatkan frekuensi tinggi dan menahan frekuensi rendah), kemudian dilanjutkan *Second Order Butterworth Low Pass Filter* (LPF Butterworth menghasilkan kerataan passband yang maksimal), dan *Notch Filter* (filter berfungsi untuk membuang atau menahan frekuensi tertentu, sedangkan frekuensi yang lain dilewatkan/diteruskan) [13].

Pada penelitian ini, *High Pass Filter* menggunakan frekuensi cut-off 1 Hz. *High Pass Filter* dipakai dengan tujuan menekan residual baseline yang menyimpang. *Second Order Butterworth Low Pass Filter* dengan frekuensi 30 Hz, bertujuan untuk mengurangi *noise* di frekuensi tinggi. *Notch Filter* bertujuan untuk mengeliminasi *Power-line interference*. *Power-line interference* disebabkan oleh radiasi dari saluran listrik bertegangan tinggi, seperti mesin ECG. Diagram alir untuk sub rutin *Preprocessing* dapat dilihat pada Gambar 3.



Gambar 3. Diagram Alir *Preprocessing*

C. Ekstraksi Ciri (*Feature Extraction*)

Data ECG dibagi menjadi data latih, validasi dan uji, dengan menggunakan *5-fold Cross Validation*. Kemudian dilanjutkan ekstraksi ciri merupakan suatu proses mengekstrak ciri atau informasi dari objek (sinyal) yang ingin dikenali atau dibedakan dengan objek lainnya. Ekstraksi ciri yang digunakan pada penelitian ini terdiri dari dua jenis, yaitu *Area Calculation* dan *Spectral Analysis*.

1) *Area Calculation*: Ekstraksi ciri *Area Binary Calculation* adalah metode ekstraksi ciri dengan menggunakan nilai maksimum antara jumlah luas *Area* sampel sinyal biner. *Area Binary Calculation* diawali dengan proses *Binary Signal Calculation* terlebih dahulu. *Binary Signal Calculation* adalah proses membandingkan data sinyal ECG dengan nilai *threshold*. Nilai yang akan diambil adalah nilai puncak maksimum (V_p) dan nilai puncak minimum (V_n) dari X_i data [14],[15].

- Jika nilai X_i terdapat di antara interval $0 < X_i \leq 0.1V_p$, maka nilai X_i akan dimasukkan ke variabel P_c .
- Jika nilai X_i terdapat di interval $0.1V_n \leq X_i \leq 0$, maka nilai X_i akan dimasukkan ke variabel N_c .

Jumlah data yang terdapat di variabel P_c dan N_c akan dijadikan parameter untuk memilih nilai *threshold*.

- Jika $P_c + N_c < 0.4n$ (n adalah jumlah sampel di *selected window*), maka nilai *Threshold* (T_d) = 0.
- Jika nilai $P_c + N_c \geq 0.4n$, dan nilai $P_c < N_c$, maka nilai $T_d = 0.2V_p$.
- Jika kondisi P_c dan N_c tidak sesuai dengan kriteria diatas, maka nilai $T_d = 0.2V_n$.


Setelah proses penentuan nilai *threshold*, nilai data X_i dibandingkan dengan nilai *Threshold*.

- Jika $X_i > T_d$, maka $S_i = 1$.
- Jika $X_i < T_d$, maka $S_i = 0$.

Pada penelitian diusulkan untuk menggunakan ekstraksi ciri Rasio *Area* ($R. Area$), yang merupakan rasio dari luas *Area* biner terhadap luas *Area* total.

$$Ratio\ Area = \frac{luas\ area\ biner}{luas\ area\ total}$$

Diagram alir *Area Calculation* dapat dilihat pada Gambar 4.



Gambar 4. Diagram Alir *Area Calculation*

2) *Spectral Analysis*: Ekstraksi ciri *Spectral Analysis* diawali dengan mengalikan setiap segmen data menggunakan *Hamming Window* dan ditransformasikan dalam domain frekuensi. Domain frekuensi diaplikasikan menggunakan *Fast Fourier Transform* (FFT). Formulasi yang digunakan dalam *Spectral Analysis* adalah sebagai berikut [16],[14]:

$$FSMN = \frac{1}{F} \times \frac{\sum A_i f_i}{\sum A_i}$$

$$A1 = \frac{\text{jumlah amplituda diantara } 0.5 - \frac{F}{2} \text{ Hz}}{\text{jumlah amplituda diantara } 0.5 - 20F \text{ Hz}}$$

$$A2 = \frac{\text{jumlah amplituda diantara } 0.7 - 1.4F \text{ Hz}}{\text{jumlah amplituda diantara } 0.5 - 20F \text{ Hz}}$$

$$A3 = \frac{\text{jumlah amplituda diantara band } 0.6 \text{ Hz dalam range } (2-8)F}{\text{jumlah amplituda diantara } 0.5 - 20F \text{ Hz}}$$

Keterangan:

F : Frekuensi amplituda puncak, rentang 0.5-9 Hz

f_i : Frekuensi ke-i data dalam FFT diantara frekuensi 0-100 Hz

A_i : Amplituda ke-i


A1: Proporsi sinyal diantara 0.5 Hz dan F/2.

A2: Proporsi sinyal diantara 0.7 F dan 1.4 F.

A3: Proporsi sinyal dalam harmonik F.

FSMN: Momen spektral pertama yang dinormalisasi.

Diagram alir *Spectral Analysis* dapat dilihat pada Gambar 5.



Gambar 5. Diagram Alir *Spectral Analysis*

D. Aritmia

Terdapat lima jenis gangguan jantung, yaitu: aktivitas listrik melewati jalur konduksi normal terlalu cepat atau terlalu lambat atau tidak beraturan (aritmia yang berasal dari sinus); aktivitas listrik berasal dari fokus selain dari nodus sinoatrial (irama ektopik); aktivitas listrik yang bentuk dan batas sirkuit ditentukan oleh karakteristik listrik atau anatomi miokardium (aritmia reentrant); aktivitas sinus yang berasal dari nodus sinoatrial dan melewati jalur normal tetapi mengalami blokade dan perlambatan di luar perkiraan (blokade konduksi); dan aktivitas listrik mengikuti jalur tambahan yang memintas jalur konduksi normal, menjadi jalan pintas listrik atau sirkuit pendek (sindrom praeksitasi) [12].

Jenis aritmia yang berasal dari sinus, terdiri dari [12]:

1) *Takikardia Sinus dan Bradikardia Sinus*: Irama sinus normal adalah irama jantung yang normal. Depolarisasi bermula dengan sendirinya dari nodus sinus. Irama sinus teratur dan berkisar 60-100 denyut per menit. Jika bertambah cepat sampai melebihi 100, irama disebut takikardia sinus. Jika melambat di bawah 60 disebut irama bradikardia sinus.

2) *Aritmia Sinus*: Aritmia sinus adalah frekuensi jantung bertambah cepat ketika inspirasi dan melambat ketika ekspirasi. Berkurangnya aritmia sinus dapat disebabkan oleh berkurangnya umpan balik negatif otonom ke nodus sinus. Karena itu, kondisi sering dijumpai pada pasien diabetes melitus yang seiring waktu dapat mengalami neuropati otonom. Aritmia sinus juga dapat berkurang akibat penuaan, obesitas dan hipertensi kronis.

3) *Sel Pacu Jantung*: Pacu jantung atrium biasanya membangkitkan impuls dengan frekuensi 60 sampai 75 denyut per menit. Sel pacu jantung yang ada di dekat nodus atrioventikular (AV) disebut juga pacu jantung tautan (junctional pacemaker), biasanya membangkitkan impuls sebanyak 40 sampai 60 denyut per menit.

4) *Aritmia Supraventrikal*: Aritmia yang berasal dari atrium atau nodus AV yaitu aritmia supraventrikal. Aritmia atrium bisa saja terdiri dari satu denyut atau gangguan irama terus-menerus yang berlangsung selama beberapa detik atau tahunan.

5) *Aritmia Ventrikanl*: Aritmia ventrikanl adalah gangguan irama yang muncul di bawah nodus Atrioventikular (AV). Ada beberapa jenis aritmia ventrikanl yaitu: Prematur Ventricular Contraction PVC), Takikardia Ventrikanl, *Ventricular Fibrillation* (VF). PVC biasanya muncul secara acak, tetapi mungkin saja muncul membentuk pola selang-seling yang teratur dengan denyut sinus normal. Takikardia ventrikanl tidak seperti PVST, morfologi takikardia ventrikanl bisa saja sama, tiap kompleks-nya tampak serupa dengan kompleks sebelumnya. Fibrilasi ventrikanl adalah satu peristiwa praterminal. VF terlihat di jantung yang hampir sekarat. VF adalah aritmia yang paling sering ditemui pada orang dewasa yang meninggal dunia mendadak. ECG naik turun secara tidak teratur (fibrilasi ventrikanl kasar) atau bergetar halus (fibrilasi ventrikanl halus). Ciri khas dari sinyal ECG VF adalah tidak ada kompleks QRS sejati.

E. Support Vector Machine

Algoritma *Machine Learning* membangun model matematika berdasarkan data sampel, dikenal sebagai pelatihan data dalam rangka untuk membuat prediksi atau keputusan tanpa secara eksplisit diprogram untuk melakukan tugas. Algoritma *Machine Learning* digunakan dalam berbagai aplikasi. *Machine Learning* terkait erat dengan komputasi statistik untuk membuat prediksi yang menggunakan komputer. Salah satu jenis *Machine Learning* yang sudah dikenal adalah *Support Vector Machine* (SVM).

Support Vector Machine (SVM) diperkenalkan oleh Vapnik pada tahun 1992 sebagai metoda unggulan dalam bidang pattern recognition [17]. Prinsip dasar SVM adalah linear classifier, yang artinya hanya dapat menangani kasus klasifikasi yang secara linier dapat dipisahkan. Konsep SVM secara sederhana sebagai usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada input space [17]. *Hyperplane* adalah sebuah garis lurus atau bidang mendatar yang berfungsi sebagai pemisah kelas. *Hyperplane* pemisah terbaik antara kedua kelas dapat ditemukan dengan mengukur margin *hyperplane* tersebut dan mencari titik maksimalnya. Margin adalah jarak antara *hyperplane* tersebut dengan pola terdekat dari masing-masing kelas [17]. Pola yang paling dekat dengan *hyperplane* pemisah terbaik disebut *support vector*.


Setelah mendapatkan nilai ekstraksi ciri, langkah selanjutnya adalah dilakukan proses latih dan uji dengan menggunakan SVM, diklasifikasikan menjadi dua kelas yaitu: VF dan Non-VF. Kemudian performansinya diukur dengan menggunakan metrik *accuracy*, *sensitivity* dan *specificity*. *Accuracy* adalah tingkat kedekatan antara nilai prediksi dengan nilai aktual. *Sensitivity* adalah pengukuran kemungkinan nilai *actual positive* terklasifikasi sebagai *positive value*. *Specificity* adalah pengukuran kemungkinan nilai *actual negative* terklasifikasi sebagai *negative value*.

III. HASIL DAN ANALISIS

Pada subbab ini akan dibahas mengenai hasil dan analisis dari *window size* ECG signal, seleksi ekstraksi ciri *Area Calculation* dan seleksi *record window* & kernel SVM.

A. Window size ECG Signal

Window size (panjang sinyal) dari sinyal ECG dilakukan 5 detik dan 10 detik, Pada Gambar 6, adalah contoh sinyal ECG (a) *record* 5 detik kelas VF, (b) *record* 5 detik kelas Non-VF, (c) *record* 10 detik kelas VF, (d) *record* 10 detik kelas Non-VF.



Gambar 6. *Window size* record 5 detik dan 10 detik

B. Seleksi Ekstraksi Ciri Area Calculation

Pada penelitian ini diusulkan penggunaan ekstraksi ciri dengan menggunakan *Ratio Area* (R. Area). Langkah pertama yang dilakukan adalah pemilihan ekstraksi ciri *Area Calculation: Area* atau R. Area, dengan menghitung performansi *accuracy*, *sensitivity* dan *specificity* dari hasil proses pengujian dengan menggunakan berbagai kernel SVM (*linear*, *quadratic*, *cubic*, *fine gaussian*, *medium gaussian*, *coarse gaussian*), diperoleh hasil seperti pada Tabel I.

TABEL I
ACCURACY, SENSITIVITY, SPECIFICITY UNTUK EKSTRAKSI CIRI AREA DAN R. AREA

Kernel	R. Area			Area		
	Accuracy	Sensitivity	Specificity	Accuracy	Sensitivity	Specificity
Linear	60%	57%	66%	61%	58%	68%
Quadratic	61%	57%	72%	59%	57%	65%
Cubic	54%	54%	54%	44%	43%	45%
Fine Gaussian	60%	57%	66%	59%	58%	60%
Medium Gaussian	63%	59%	71%	61%	58%	66%
Coarse Gaussian	61%	57%	72%	59%	55%	76%
Rata-rata	60%	57%	67%	57%	55%	63%

Dari Tabel I terlihat bahwa ekstraksi ciri R. Area menunjukkan performansi yang lebih stabil di semua metrik (*accuracy*, *sensitivity*, *specificity*), dengan *accuracy*: 54%-63%, sedangkan pada ekstraksi ciri Area dengan *accuracy*: 44%-61%. Dari hasil rata-rata performance metric dari seluruh kernel ekstraksi ciri R. Area mengungguli ekstraksi ciri Area dengan *accuracy*: 60%, *sensitivity*: 57% dan *specificity*: 67%. Sehingga pada penelitian ini ekstraksi ciri R. Area akan dipilih untuk selanjutnya dikombinasi dengan ekstraksi ciri *spectral*.

C. Seleksi Record Window & Kernel SVM

Sebelum dilakukan kombinasi ekstraksi ciri, dilakukan seleksi *record* dengan *window size* yang akan digunakan 5 detik atau 10 detik, dengan cara menggunakan seluruh ekstraksi ciri (lima ekstraksi ciri), sekaligus dilakukan perbandingan berbagai kernel untuk model klasifikasi VF atau Non-VF dengan menggunakan SVM. Pengujian dilakukan pada ekstraksi ciri: FSMN, A1, A2, A3, R. Area hasilnya terlihat pada Tabel II.

TABEL II
ACCURACY, SENSITIVITY, SPECIFICITY DARI LIMA EKSTRAKSI CIRI (RECORDS 10 DETIK DAN 5 DETIK) DENGAN BERBAGAI KERNEL SVM

Records	Performance Metric	Kernel SVM					
		Linear	Quadratic	Cubic	Fine Gaussian	Medium Gaussian	Coarse Gaussian
10 detik	Accuracy	93%	95%	93%	85%	88%	87%
	Sensitivity	91%	96%	94%	84%	91%	91%
	Specificity	96%	94%	92%	86%	85%	84%
5 detik	Accuracy	77%	73%	68%	66%	75%	76%
	Sensitivity	78%	76%	69%	77%	77%	77%
	Specificity	76%	71%	67%	61%	74%	75%

Pada Tabel II, performansi dari model SVM untuk *window size* 5 detik dan 10 detik, serta performansi dari keenam kernel SVM, menunjukkan bahwa *Quadratic Kernel* mencapai *accuracy* tertinggi 95% pada *record* 10 detik, sementara *Linear kernel* paling robust pada *record* 5 detik dengan *accuracy*: 77%.

Nilai performansi dari *records* 10 detik (*accuracy*: 85%-95%, *sensitivity*: 84%-96%, *specificity*: 84%-96%) mengungguli dari *records* 5 detik (*accuracy*: 66%-77%, *sensitivity*: 69%-78%, *specificity*: 61%-76%). Sehingga selanjutnya pengujian untuk klasifikasi VF/ Non- VF dengan SVM hanya akan menggunakan *records* dengan *window size* 10 detik dan *Quadratic kernel*.

D. Performance Metric dari Kombinasi Ekstraksi Ciri

Pengukuran performansi untuk setiap kombinasi ekstraksi ciri (FSMN, A1, A2, A3, R. Area), diawali dengan performansi dari satu ekstraksi ciri, hingga kombinasi dari: dua hingga lima ekstraksi ciri. Hasil *accuracy*, *sensitivity*, dan *specificity* dari satu ekstraksi ciri terlihat pada Tabel III.

TABEL III
HASIL *ACCURACY*, *SENSITIVITY*, *SPECIFICITY* DARI SATU EKSTRAKSI CIRI DENGAN *QUADRATIC KERNEL*

Ekstraksi Ciri	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>
FSMN	72%	69%	76%
A1	48%	48%	48%
A2	68%	82%	63%
A3	77%	78%	76%
R. Area	61%	57%	72%

Berdasarkan Tabel III, ekstraksi ciri A3 menunjukkan performansi terbaik dengan (*accuracy* 77%, *sensitivity* 78%, *specificity* 76%), diikuti oleh ekstraksi ciri FSMN (*accuracy* 77%, *sensitivity* 78%, *specificity* 76%), Sementara itu, ekstraksi ciri A1 menunjukkan performansi terendah dengan *accuracy* 48%, *sensitivity* 48%, *specificity* 48%.

Kemudian dilakukan pengukuran performansi untuk klasifikasi VF/ Non-VF dengan SVM dengan kombinasi dari dua ekstraksi ciri menggunakan *Quadratic Kernel* (lihat Tabel IV).

TABEL IV
HASIL *ACCURACY*, *SENSITIVITY*, *SPECIFICITY* KOMBINASI DUA CIRI DENGAN *QUADRATIC KERNEL*

Ekstraksi Ciri	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>
FSMN-A1	87%	88%	86%
FSMN-A2	95%	96%	94%
FSMN-A3	96%	94%	98%
FSMN-R. Area	81%	78%	84%
A1-A2	62%	69%	59%
A1-A3	76%	76%	76%
A1-R. Area	62%	59%	67%
A2-A3	77%	79%	75%
A2-R. Area	66%	72%	63%
A3-R. Area	77%	75%	79%

Hasil menunjukkan bahwa kombinasi dua ekstraksi ciri memberikan peningkatan performansi dibandingkan penggunaan satu ekstraksi ciri. Kombinasi terbaik adalah FSMN-A3 (*accuracy* 96%, *sensitivity* 94%, *specificity* 98%), diikuti oleh FSMN-A2 (*accuracy* 95%, *sensitivity* 96%, *specificity* 94%). Kombinasi dua ekstraksi ciri yang terendah adalah A1-A2 (*accuracy* 62%, *sensitivity* 69%, *specificity* 59%) dan A1-R. Area (*accuracy* 62%, *sensitivity* 59%, *specificity* 67%).

TABEL VII
HASIL *ACCURACY*, *SENSITIVITY*, *SPECIFICITY* KOMBINASI TIGA CIRI DENGAN *QUADRATIC KERNEL*

Ekstraksi Ciri	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>
FSMN-A1-A2	97%	100%	94%
FSMN-A1-A3	96%	98%	94%
FSMN-A1-R. Area	92%	90%	94%
FSMN-A2-A3	96%	98%	94%
FSMN-A2-R. Area	97%	98%	96%
FSMN-A3-R. Area	95%	94%	96%
A1-A2-A3	69%	74%	66%
A1-A2-R. Area	63%	64%	62%
A1-A3-R. Area	73%	72%	74%
A2-A3-R. Area	74%	77%	71%

Pada Tabel III, hasil menunjukkan bahwa kombinasi tiga ekstraksi ciri dengan FSMN mencapai peningkatan performansi, dengan *accuracy* 92%-97%, *sensitivity* 90%-100%, *specificity* 94%-96%. Terdapat dua hasil kombinasi terbaik yang mencapai *accuracy* 97%, *sensitivity* 100%, *specificity* 94% yaitu: FSMN-A1-A2 dan FSMN-A2-R. Area. Sementara kombinasi tanpa ekstraksi ciri FSMN menunjukkan performansi jauh lebih rendah dengan *accuracy* hanya sebesar 63%-74%.

TABEL VIV
HASIL *ACCURACY*, *SENSITIVITY*, *SPECIFICITY* KOMBINASI 4 CIRI DENGAN *QUADRATIC KERNEL*

Ekstraksi Ciri	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>
FSMN-A1-A2-R. <i>Area</i>	95%	96%	94%
FSMN-A1-A3-R. <i>Area</i>	95%	96%	94%
FSMN-A2-A3-R. <i>Area</i>	95%	96%	94%
A1-A2-A3-R. <i>Area</i>	72%	76%	69%
FSMN-A1-A2-A3	95%	98%	92%

Pada Tabel IV kombinasi dari empat ekstraksi ciri mencapai *accuracy* sebesar 95%. Terdapat tiga kombinasi dengan FSMN dan R. *Area* menghasilkan hasil yang sama yaitu: FSMN-A1-A2-R. *Area*, FSMN-A1-A3-R. *Area* dan FSMN-A2-A3-R. *Area* (*accuracy* 95%, *sensitivity* 96%, *specificity* 94%). Penambahan ekstraksi ciri menjadi empat ekstraksi ciri, tidak meningkatkan performansi dibanding kombinasi tiga ekstraksi ciri (*accuracy* 97%), bahkan menunjukkan penurunan *accuracy* sebesar 2%.

TABEL V
HASIL *ACCURACY*, *SENSITIVITY*, *SPECIFICITY*, KOMBINASI LIMA CIRI DENGAN *QUADRATIC KERNEL*

Ekstraksi Ciri	<i>Accuracy</i>	<i>Sensitivity</i>	<i>Specificity</i>
FSMN-A1-A2-A3-R. <i>Area</i>	95%	96%	94%

Pada Tabel V, adalah kombinasi lima ekstraksi ciri (FSMN-A1-A2-A3-R. *Area*) dengan menggunakan semua ciri yang ada, menghasilkan *accuracy* sebesar 95% dengan *sensitivity* 96% dan *specificity* 94%. Tidak ada peningkatan performansi dan hasilnya hampir sama dengan kombinasi empat ekstraksi ciri.

IV. SIMPULAN

Pada penelitian ini telah dilakukan kombinasi ekstraksi ciri untuk klasifikasi menggunakan *Support Vector Machine* (SVM) dengan *Quadratic Kernel* dan *window size* 10 detik, hasil evaluasi dari satu ekstraksi ciri hingga kombinasi dua hingga lima ekstraksi ciri. Hasil yang diperoleh menunjukkan kombinasi tiga ekstraksi ciri FSMN-A1-A2 mencapai performa tertinggi dengan *accuracy* 97%, *sensitivity* 100%, *specificity* 94% dan kombinasi ekstraksi ciri FSMN-A2-R. *Area* mencapai akurasi 97%, *sensitivity* 98%, *specificity* 96%. Penambahan ekstraksi ciri dari tiga menjadi empat ekstraksi ciri tidak meningkatkan performansi secara signifikan, hal ini menunjukkan efisiensi kombinasi dari tiga ekstraksi ciri. Kombinasi dua ekstraksi ciri (FSMN-A3) memberikan *cost-benefit Ratio* optimal dengan *accuracy* 96% pada pengurangan komputasi 50% jika dibandingkan dengan konfigurasi tiga ekstraksi ciri, menjadikannya tepat untuk dipilih dengan keterbatasan sumber daya komputasi.

Dengan melibatkan FSMN sebagai ekstraksi ciri performansi *accuracy* mencapai lebih dari 92%, sedangkan kombinasi tanpa ekstraksi ciri FSMN hanya mencapai *accuracy* maksimal 77%, sehingga dapat disimpulkan bahwa FSMN sebagai ekstraksi ciri yang dominan dalam klasifikasi VF/ Non-VF.

Beberapa usulan untuk pengembangan penelitian selanjutnya adalah bisa mengimplementasikannya dengan menggunakan metode ensemble dengan *multiple classifiers*. Selain itu untuk dilakukan studi perbandingan antara metode SVM dengan *Deep Learning* (CNN, RNN, Transformer).

DAFTAR PUSTAKA

- [1] A. Mjahed and A. Rosado-Muñoz, "Hybrid CNN-Fuzzy Approach for Automatic Identification of Ventricular Fibrillation and Tachycardia," *Applied Sciences*, vol. 15, no. 17, p. 9289, Aug. 2025, doi: 10.3390/app15179289.
- [2] G. Salama and B.-R. Choi, "Imaging Ventricular Fibrillation," *Journal of Electrocardiology*, vol. 40, no. 6, pp. S56–S61, Nov. 2007, doi: 10.1016/j.jelectrocard.2007.06.021.
- [3] M. F. Pérez-Gutiérrez et al., "Spectral Analysis and Mutual Information Estimation of Left and Right Intracardiac Electrograms during Ventricular Fibrillation," *Sensors*, vol. 20, no. 15, p. 4162, Jul. 2020, doi: 10.3390/s20154162.
- [4] M. J. Reed, G. R. Clegg, and C. E. Robertson, "Analysing the Ventricular Fibrillation waveform," *Resuscitation*, vol. 57, no. 1, pp. 11–20, Apr. 2003, doi: 10.1016/S0300-9572(02)00441-0.
- [5] A. Amann, R. Tratnig, and K. Unterkofler, "Reliability of old and new Ventricular Fibrillation detection algorithms for Automated External Defibrillators," *BioMed Eng OnLine*, vol. 4, no. 1, p. 60, Dec. 2005, doi: 10.1186/1475-925X-4-60.
- [6] Qiao Li, C. Rajagopalan, and G. D. Clifford, "Ventricular Fibrillation and Tachycardia Classification Using a Machine Learning Approach," *IEEE Trans. Biomed. Eng.*, vol. 61, no. 6, pp. 1607–1613, Jun. 2014, doi: 10.1109/TBME.2013.2275000.
- [7] F. Alonso-Atienza, J. L. Rojo-Álvarez, A. Rosado-Muñoz, J. J. Vinagre, A. García-Alberola, and G. Camps-Valls, "Feature selection using Support Vector Machines and bootstrap methods for Ventricular Fibrillation detection," *Expert Systems with Applications*, vol. 39, no. 2, pp. 1956–1967, Feb. 2012, doi: 10.1016/j.eswa.2011.08.051.
- [8] A. Picon et al., "Mixed convolutional and long short-term memory network for the detection of lethal ventricular arrhythmia," *PLoS ONE*, vol. 14, no. 5, p. e0216756, May 2019, doi: 10.1371/journal.pone.0216756.
- [9] U. R. Acharya et al., "Automated identification of shockable and non-shockable life-threatening ventricular arrhythmias using convolutional neural network," *Future Generation Computer Systems*, vol. 79, pp. 952–959, Feb. 2018, doi: 10.1016/j.future.2017.08.039.

- [10] Md. A. Awal, S. S. Mostafa, M. Ahmad, and M. A. Rashid, "An adaptive level dependent wavelet *thresholding* for ECG denoising," *Biocybernetics and Biomedical Engineering*, vol. 34, no. 4, pp. 238–249, 2014, doi: 10.1016/j.bbe.2014.03.002.
- [11] G. B. Moody and R. G. Mark, "The impact of the MIT-BIH Arrhythmia Database," *IEEE Eng. Med. Biol. Mag.*, vol. 20, no. 3, pp. 45–50, Jun. 2001, doi: 10.1109/51.932724.
- [12] "The Only EKG Book You'll Ever Need, 9e -- Malcolm S. Thaler, M.D."
- [13] Z. F. Issa, J. M. Miller, and D. P. Zipes, *Clinical arrhythmology and electrophysiology: a companion to Braunwald's heart disease*, Third edition. Philadelphia, PA: Elsevier, 2019.
- [14] R. H. Clayton, A. Murray, and R. W. F. Campbell, "Recognition of *Ventricular Fibrillation* using neural networks," *Med. Biol. Eng. Comput.*, vol. 32, no. 2, pp. 217–220, Mar. 1994, doi: 10.1007/BF02518922.
- [15] Xu-Sheng Zhang, Yi-Sheng Zhu, N. V. Thakor, and Zhi-Zhong Wang, "Detecting ventricular tachycardia and fibrillation by complexity measure," *IEEE Trans. Biomed. Eng.*, vol. 46, no. 5, pp. 548–555, May 1999, doi: 10.1109/10.759055.
- [16] S. Barro, R. Ruiz, D. Cabello, and J. Mira, "Algorithmic sequential decision-making in the frequency domain for life threatening ventricular arrhythmias and imitative artefacts: a diagnostic system," *Journal of Biomedical Engineering*, vol. 11, no. 4, pp. 320–328, Jul. 1989, doi: 10.1016/0141-5425(89)90067-8.
- [17] C. Cortes and V. Vapnik, "Support-vector networks," *Mach Learn*, vol. 20, no. 3, pp. 273–297, Sep. 1995, doi: 10.1007/BF00994018.