

Klasifikasi Sinyal EKG menggunakan Ciri Statistik dan Parameter Hjorth dengan SVM dan k-NN

INUNG WIJAYANTO¹, ANNISA HUMAIRANI², ACHMAD RIZAL³, SUGONDO HADIYOSO⁴

^{1,2,3}Fakultas Teknik Elektro, Universitas Telkom, Bandung

⁴Fakultas Ilmu Terapan, Universitas Telkom, Bandung

Email: iwijayanto@telkomuniversity.ac.id

Received 31 Juli 2021 | Revised 24 Agustus 2021 | Accepted 16 September 2021

ABSTRAK

Sinyal elektrokardiogram (EKG) dapat dianalisis dengan memperhatikan bentuk, durasi, dan irama. Pada penelitian ini, dikembangkan sebuah metode ekstraksi ciri sinyal EKG dengan menggunakan parameter Hjorth dan ciri statistik. Kedua parameter tersebut diaplikasikan untuk mengekstrak ciri-ciri dari rekaman suara sinyal EKG. Terdapat tiga kondisi rekaman sinyal EKG yang menjadi masukan dari sistem, kondisi normal, atrial fibrillation (AF), dan congestive heart failure (CHF). Set ciri rekaman EKG yang didapatkan kemudian diklasifikasikan dengan menggunakan metode support vector machine (SVM) dan k-Nearest Neighbor (k-NN) untuk dibandingkan performansinya. Hasil pengujian menggunakan semua ciri sebagai prediktor menunjukkan bahwa usulan sistem mampu memberikan akurasi sebesar 100%. Sementara itu pada skenario reduksi ciri dimana hanya dua ciri yaitu skewness dan complexity, performansi sistem tidak berkurang. Komparasi dengan beberapa studi sebelumnya menunjukkan bahwa usulan metode lebih unggul dalam hal akurasi deteksi dan jumlah ciri yang digunakan.

Kata kunci: EKG, atrial fibrillation, congestive heart failure, Hjorth, SVM, k-NN

ABSTRACT

An electrocardiogram (ECG) signal can be analyzed by paying attention to its shape, duration, and rhythm. In this study, feature extraction for ECG signals is applied using the Hjorth parameter and statistical characteristics. These two parameters are applied to extract the characteristics of the ECG signal sound recording. There are three conditions of ECG signal recording that are used as input for the system. They are normal conditions, atrial fibrillation (AF), and congestive heart failure (CHF). The set of ECG recording features are classified using the support vector machine (SVM) and k-Nearest Neighbor (k-NN) methods. The test results using all features show that the proposed system can achieve 100% of accuracy. On the other hand, by reducing the feature using only skewness and complexity, the system's performance is not reduced. Comparative studies with several previous studies show that the proposed method is superior in detection accuracy and the number of features used.

Keywords: ECG, atrial fibrillation, congestive heart failure, Hjorth, SVM, k-NN

1. PENDAHULUAN

Sinyal elektrokardiogram (EKG) mencerminkan aktivitas listrik otot jantung. Sinyal EKG terkait dengan berbagai proses kimia, listrik, dan mekanis yang saling terkait dan kompleks yang ada di dalam jantung (**Abo-Zahhad, dkk, 2014**). Sinyal EKG mengandung banyak informasi diagnostik yang berharga seperti penggambaran fungsi jantung dan sistem sirkulasi atau sistem saraf (**Kærgaard, dkk, 2016**). Sinyal EKG dianalisis berdasarkan irama, durasi, orientasi, dan bentuk (**Agrawal & Gupta, 2013**). Setiap perubahan bentuk, irama, durasi, dan bentuk mengisyaratkan adanya kelainan pada jantung. Kelainan jantung dikenali oleh dokter ahli jantung berdasarkan keahlian dan pengalamannya. Dengan kemajuan teknologi pengolahan sinyal digital maka dikembangkan berbagai metode untuk mengenali kelainan jantung berdasarkan sinyal EKG secara otomatis.

Sinyal EKG telah menjadi subjek penelitian selama bertahun-tahun (**Gacek & Pedrycz, 2012**). Beberapa yang menjadi fokus dari penelitian sinyal EKG adalah pengurangan derau, deteksi gelombang, dan ekstraksi ciri. Pengurangan derau ditujukan untuk menghilangkan sinyal lain yang mengganggu sinyal EKG seperti sinyal otot, interferensi frekuensi rendah, interferensi tegangan jala-jala, dan interferensi elektromagnetik (**Luo & Johnston, 2010**). Deteksi gelombang ditujukan untuk mengidentifikasi gelombang tertentu pada sinyal EKG sebagai fase pembentukan sinyal EKG seperti gelombang P, deteksi QRS, dan deteksi segmen ST (**Pal & Mitra, 2012**). Ekstraksi ciri pada sinyal EKG ditujukan untuk mengurangi dimensi sinyal EKG supaya lebih mudah digunakan untuk memudahkan klasifikasi sinyal EKG. Proses ekstraksi ciri dapat dikategorikan ke dalam empat kategori pengolahan data: (a) berbasis waktu, (b) berbasis frekuensi, (c) berbasis waktu-frekuensi, dan (d) nonlinier (**Hagiwara dkk., 2018**). Proses ekstraksi ciri berbasis waktu diantaranya adalah *Principal Component Analysis* (PCA), *Linear Discriminant Analysis* (LDA), dan *Independent Component Analysis* (ICA) (**Joy, dkk, 2013**). Ekstraksi ciri berbasis frekuensi biasanya menggunakan *Fast Fourier Transform* (FFT) untuk mengubah sinyal dari sinyal EKG dari domain waktu ke domain frekuensi. Sementara itu, analisis berbasis frekuensi waktu diantaranya menggunakan *Sort-Time Fourier Transform* (STFT) atau *Stockwell transform* (S-transform) (**Pratiwi, dkk, 2020**). Analisis sinyal EKG menggunakan pendekatan non-linear seperti menggunakan *entropy* (**Chen, dkk., 2013**) (**Rizal & Wijayanto, 2019**) atau dimensi *fractal* (**Mercy Cleetus & Singh, 2014**) (**Ruiz-Padial & Ibáñez-Molina, 2018**) juga dapat digunakan untuk mendapatkan karakteristik kuantitatif sinyal EKG.

Penelitian ini mengembangkan metode ekstraksi ciri sinyal EKG dengan menggunakan parameter Hjorth dan ciri statistik. Set ciri tersebut kemudian digunakan sebagai masukan klasifikasi sinyal EKG menggunakan *Support Vector Machine* (SVM) dan *k-Nearest Neighbor* (k-NN). Kondisi sinyal EKG yang diolah merupakan sinyal EEG yang terdiri dari tiga kelas data, yaitu kondisi normal, *atrial fibrillation* (AF), dan *congestive heart failure* (CHF). Dari penelitian ini diharapkan dapat diketahui ciri apa yang menghasilkan akurasi tertinggi untuk klasifikasi sinyal EKG secara otomatis.

2. MATERIAL DAN METODE

2.1 Set Data Sinyal EKG

Set data sinyal EKG bersumber dari basis data MIT-BIH yang secara resmi tersimpan di basis data Physionet (**Physionet.org, 2010**). *Normal Sinus Rhythm* (NSR), *Congestive Heart Failure* (CHF), dan *Atrial Fibrillation* (AF) merupakan tiga kelas yang digunakan dari *database*

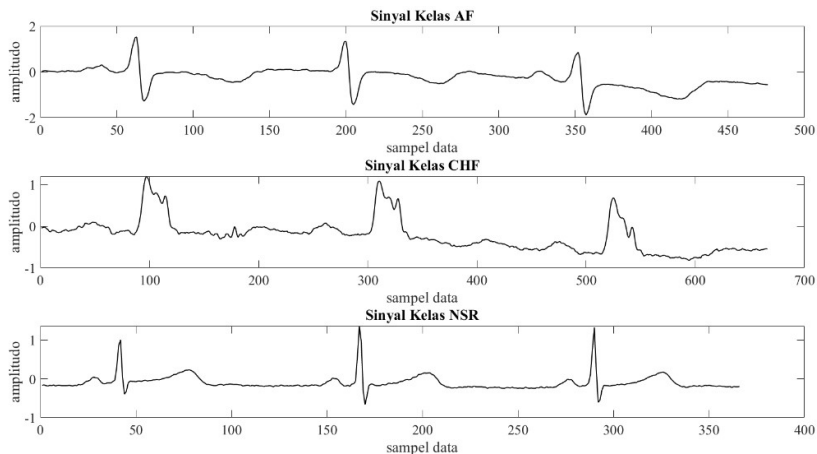
MIT-BIH. Data sinyal EKG dari masing-masing kelas berjumlah 50 data dengan frekuensi cuplikan 250 Hz dan panjang 2-3 detik QSR. NSR menyatakan kondisi normal, sementara AF dan CHF menyatakan kondisi tidak normal. Perbedaan dari sinyal AF dan CHF terletak pada penyebabnya. Sinyal kelas AF disebabkan oleh degenerasi *atrial* sehingga ritme tidak beraturan. Sementara itu, sinyal kelas CHF muncul saat jantung tidak mampu memompa jantung secara efektif dan banyaknya darah yang tersalurkan kurang dari kebutuhan tubuh **(Schuster, dkk, 2002) (Al-khatib, dkk, 2013)**. Gambar 1 menunjukkan sampel dari setiap kelas sinyal EKG pada MIT-BIH *database*.

Setiap data di *database* MIT-BIH memiliki komponen DC yang harus dihilangkan terlebih dahulu. Lalu, dilakukan proses normalisasi amplitudo sinyal. Perhitungan untuk menghilangkan komponen DC (s_{dc}) dan normalisasi (s_{norm}) ditulis secara matematis pada Persamaan (1) dan (2), secara berurutan.

$$s_{dc} = s(n) - \frac{1}{N} \sum_{i=1}^N s(n) \quad (1)$$

$$s_{norm}(n) = \frac{s_{dc}}{\max|s_{dc}|} \quad (2)$$

dengan $s(n)$ adalah sinyal EKG sebagai sinyal masukan, N adalah jumlah sinyal, dan s_{dc} adalah sinyal tanpa komponen DC, dan $s_{norm}(n)$ adalah sinyal ternormalisasi dengan nilai antara -1 dan +1.



Gambar 1. Sampel Sinyal EKG Kelas AF, CHF, dan NSR.

2.2 Ciri Statistik

Ciri statistik memiliki kemampuan untuk mengekstrak variabilitas yang ada di dalam sinyal EKG **(Bavkar, dkk, 2019)**. Penggunaan ciri statistik bertujuan untuk menangkap informasi penting dengan dimensi data yang tetap rendah **(Alickovic, dkk, 2018)**. Pada penelitian ini, digunakan lima jenis ciri statistik, yaitu *mean* (μ), *variance* (σ^2), *skewness* (sk), *kurtosis* (ku), dan entropi ($H(s)$), yang mengekstrak $s_{norm}(n)$ dengan Persamaan (3)-(7) berikut

$$\mu = \frac{1}{N} \sum_{i=1}^N s_{norm_i} \quad (3)$$

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (s_{norm_i} - \mu)^2 \quad (4)$$

$$sk = \frac{\frac{1}{N} \sum_{i=1}^N (s_{norm_i} - \mu)^3}{\sigma^3} \quad (5)$$

$$ku = \frac{\frac{1}{N} \sum_{i=1}^N (s_{norm_i} - \mu)^4}{\sigma^4} \quad (6)$$

$$H(S) = - \sum_{i=1}^n P(s_{norm_i}) \log_2 P(s_{norm_i}) \quad (7)$$

Dimana σ adalah standar deviasi (**Esmael, dkk, 2013**).

2.3 Parameter Hjorth

Parameter Hjorth, diperkenalkan pertama kali oleh B. Hjorth, berguna untuk mengukur karakteristik sinyal EKG (**Hjorth, 1970**). Parameter Hjorth terdiri dari *activity* (*ac*), *mobility* (*mob*), dan *complexity* (*com*) yang menghitung daya sinyal, rata-rata frekuensi sinyal, dan perubahan di frekuensi, secara berurutan. Dalam menghitung ketiga parameternya, Hjorth menggunakan parameter *variance* sehingga kompleksitas komputasinya menjadi rendah dan tetap memperoleh informasi spektrum frekuensi yang terdapat di sinyal EKG (**Patil, dkk, 2016**). Persamaan parameter Hjorth ditunjukkan pada Persamaan (8)-(10).

$$ac = \sigma_0^2 \quad (8)$$

$$mob = \frac{\sigma_1^2}{\sigma_0^2} \quad (9)$$

$$com = \sqrt{\left(\frac{\sigma_{n+1}^2}{\sigma_n^2} - \frac{\sigma_n^2}{\sigma_{n-1}^2} \right)} \quad (10)$$

dengan σ_0^2 adalah *variance* dari sinyal $s_{norm}(n)$, σ_1^2 adalah turunan pertama dari *variance*, dan n adalah orde. Orde yang digunakan pada penelitian sama dengan satu karena kemiripan sinyal dapat diukur dengan baik (**Hjorth, 1973**).

2.4 Cross Validation

Cross Validation (CV) digunakan untuk mengoptimasi *classifier* dalam mengevaluasi kinerja sistem model (**Abbaszadeh, dkk, 2019**). Sistem model dilatih dan diuji sebanyak k kali dan diperoleh akurasi rata-rata. Nilai k ditentukan pada k -fold CV. Nilai k yang berbeda menghasilkan nilai akurasi yang berbeda di setiap jalannya program. Meskipun begitu, perubahan nilai akurasi tidak berbeda jauh. Penelitian ini menggunakan 5-fold CV dan 10-fold CV yang berarti sistem model dilatih dan diuji sebanyak 5 dan 10 kali.

2.5 Support Vector Machine (SVM)

Metode *Support Vector Machine* (SVM) dikemukakan oleh Vapnik sekitar tahun 1992 untuk melakukan klasifikasi dua kelas (**Cortes & Vapnik, 1995**). Pada perkembangannya, metode ini kemudian dapat digunakan untuk melakukan klasifikasi kelas banyak. Proses utama yang

dilakukan oleh SVM adalah dengan memisahkan dua kelompok data menggunakan sebuah *vector space* yang disebut dengan *hyperplane*. Terdapat dua jenis SVM, yaitu linier dan nonlinier, keduanya dibedakan melalui jenis fungsi kernel, diantaranya *Radial Basis Function* (RBF) dan polinomial.

Jika sebuah set data yang diekspresikan dengan (x_i, y_i) , $i = 1, 2, 3, \dots, l$, $x \in R^N$, dimana $y_i \in \{-1, +1\}$ adalah identitas dari tiap kelas. Fungsi diskriminan dari SVM ditunjukkan pada Persamaan (11).

$$y_i [(w \cdot x_i) + b] - 1 \geq 0, \quad i = 1, 2, 3, \dots, l \quad (11)$$

Dengan menggunakan pengali Lagrange, Persamaan tersebut dapat diubah menjadi sebuah fungsi objektif sebagaimana ditunjukkan pada Persamaan (12).

$$\min Q(a) = \frac{1}{2} \sum_{i,j=1}^l a_i a_j y_i y_j \cdot K(x_i, x_j) - \sum_{i=1}^l a_i \quad (12)$$

Dimana a_i adalah pengali Lagrange, K adalah fungsi kernel yang digunakan untuk perhitungan yang dijabarkan pada Persamaan (13)

$$K(a, a_i) = \frac{\exp(-|a - a_i|^2)}{g^2} \quad (13)$$

Penelitian ini menggunakan tiga buah kernel SVM yaitu kernel linier, polinomial dan RBF. Persamaan tiap kernel secara berurutan ditunjukkan oleh Persamaan (14-15)

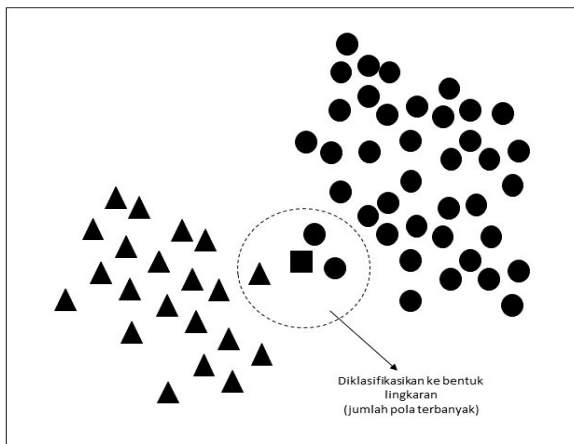
$$K(a, a_i) = a_i^T a \quad (14)$$

$$K(a, a_i) = (a_i^T a + 1)^d \quad (15)$$

$$K(a, a_i) = \exp\left\{-\|a - a_i\|_2^2 / \sigma^2\right\} \quad (16)$$

2.6 k-Nearest Neighbor (K-NN)

Metode k-Nearest Neighbour (k-NN) merupakan salah satu *Instance-Based Learning* (IBL) yang tidak membutuhkan proses pembelajaran dari data latih. Proses ini diganti dengan secara langsung mengambil keputusan berdasarkan sejumlah data dari tetangga yang memiliki jarak yang mirip dengan pola data masukan. k-NN mencari pola sebanyak k yang memiliki jarak terdekat dengan masukan dengan melakukan *voting* (Suyanto, 2018). Ilustrasi proses klasifikasi k-NN dengan $k = 3$ dapat dilihat pada Gambar 2.



Gambar 2. Ilustrasi Klasifikasi k-NN dengan k=3

2.7 Evaluasi Performansi

Performansi dari sistem yang dibangun diukur dengan menggunakan tiga parameter utama, yaitu akurasi, sensitivitas, dan spesifisitas. Ketiga parameter tersebut dihitung dengan memperhatikan nilai positif betul (PB), negatif betul (NB), positif salah (PS), dan negatif salah (NS).

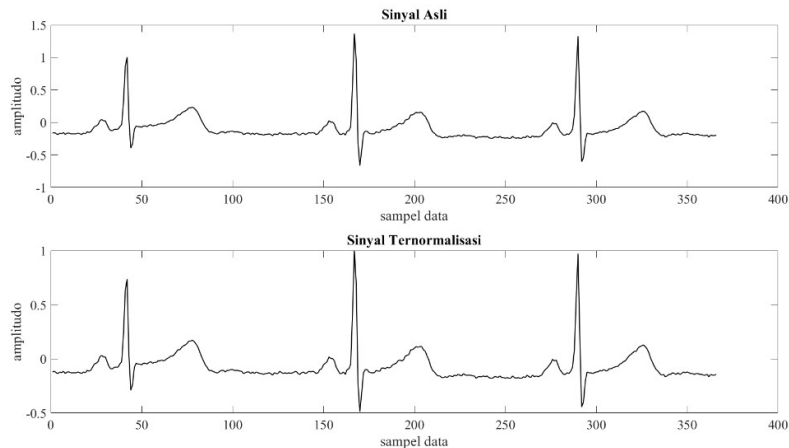
$$\text{sensitivitas} = \frac{PB}{NB + NS} \times 100 \quad (17)$$

$$\text{spesifisitas} = \frac{NB}{NB + NS} \times 100 \quad (18)$$


$$\text{akurasi} = \frac{PB + NB}{PB + NB + PS + NS} \times 100 \quad (19)$$

3. HASIL DAN DISKUSI

Gambar 3 menunjukkan sinyal EKG setelah dilakukan normalisasi sehingga sinyal tersebut mempunyai rentang amplitudo dari -1 hingga 1 mV. Proses normalisasi ini tidak mengubah bentuk dasar sinyal namun dapat menurunkan deviasi ciri inter-kelas sinyal EKG. Sinyal EKG yang telah dinormalisasi kemudian dihitung cirinya menggunakan analisis statistik dan Hjorth parameter. Total ciri yang dihasilkan dari tahap ekstraksi ciri adalah delapan ciri kuantitatif. Hasil rata-rata ciri setiap kelas sinyal EKG untuk masing-masing parameter dalam bentuk grafik disajikan pada Gambar 4. Dari Gambar 4 dapat dilihat bahwa ciri masing-masing kelas mempunyai nilai kuantitatif yang berbeda satu sama lain. Nilai *overlap* antar kelas juga cenderung rendah ditunjukkan dengan nilai standar deviasi yang kecil. Jika kita menyoroti ciri *skewness*, sinyal CHF mempunyai perbedaan signifikan dengan dua sinyal lainnya. *Skewness* pada CHF bernilai negatif sedangkan dua kelas EKG lainnya bernilai positif. Dengan demikian, hasil ini memberikan dugaan awal bahwa pada proses klasifikasi akan menghasilkan akurasi tinggi. Vektor ciri yang di-*generate* kemudian menjadi *predictor* pada proses klasifikasi.



Gambar 3. Sinyal EKG Mentah dan Sinyal EKG Ternormalisasi

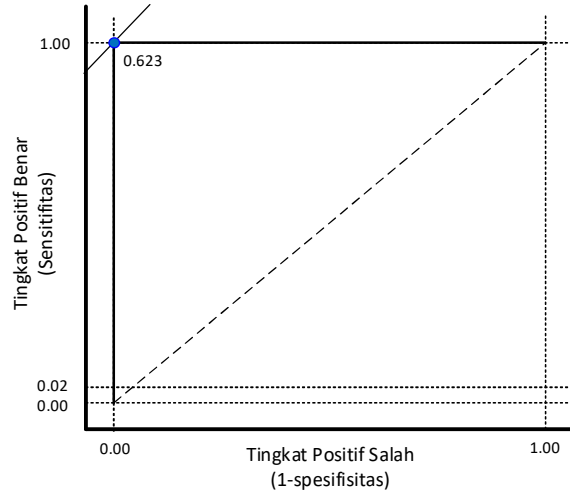


Gambar 4. Rata-rata Ciri untuk Masing-masing Kelas Sinyal EKG

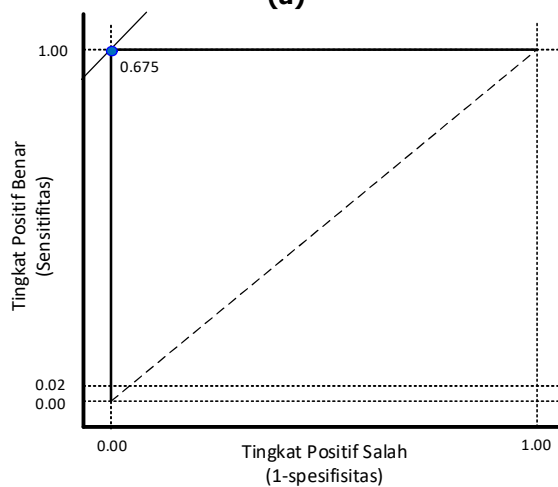
Tahap berikutnya dilakukan evaluasi performa usulan metode dengan melakukan klasifikasi menggunakan SVM dan k-NN. *Cross validation* diterapkan pada pengujian ini mencakup 5 dan 10 *cross validation* dalam membagi data latih dan data uji. Beberapa skenario pemilihan kernel pada SVM dan variasi jumlah k pada k-NN juga diaplikasikan untuk mengetahui performa terbaik. Hasil uji kinerja dari sistem ini berupa grafik *Receiver Operating Characteristic* (ROC) dan akurasi A dalam bentuk *confusion matrix*.

Grafik ROC untuk masing-masing kelas disajikan pada Gambar 5. Dapat dilihat bahwa nilai positif salah ditunjukkan pada sumbu x, sedangkan nilai positif betul pada sumbu y. Semakin dekat bentuk kurva ROC ke arah kiri dan batas atas area ROC, maka semakin akurat kinerja *classifier*. Dari seluruh grafik ROC dapat disimpulkan bahwa sistem ini mempunyai kinerja sangat baik, diindikasikan dengan area ROC pada koordinat (0,1). Prediksi kelas benar adalah 1 dan prediksi kelas salah adalah 0. Sementara itu, hasil evaluasi performa dalam bentuk akurasi sebagaimana disajikan pada Tabel 1, memberikan nilai akurasi prediksi hingga 100%


menggunakan SVM dengan kernel linear dan RBF dan k-NN untuk semua k. Hasil *confusion matriks* ditunjukkan pada Gambar 6.



(a)



(b)

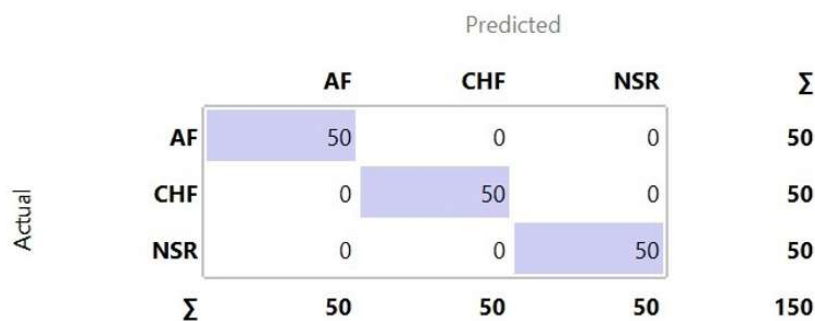


(c)

Gambar 5. Grafik Receiver Operating Characteristic (ROC) (a) AF (b) CHF (b) NSR

Tabel 1. Akurasi Klasifikasi

<i>Classifier</i>	<i>Cross Validation</i>	Akurasi (%)
SVM	Linear	100
	RBF	5
	Polinomial	99.33
	Linear	100
	RBF	10
	Polinomial	99.33
k-NN	k=1	100
	k=3	5
	k=5	100
	k=1	100
	k=3	10
	k=5	100



Gambar 6. Confusion Matrix

Evaluasi performa usulan sistem juga dilakukan dengan mereduksi jumlah ciri. Tujuannya adalah mendapatkan performa terbaik dengan menggunakan jumlah ciri yang sedikit. Sebagaimana ditunjukkan pada Gambar 4, secara visual antar kelas mempunyai perbedaan ciri signifikan khususnya pada ciri *skewness*, *kurtosis*, *entropy*, *mobility*, dan *complexity*. Oleh karena itu, pada skenario ini diambil dua ciri dimana masing-masing mewakili ciri statistik dan Hjorth. Dari sini diperoleh enam pasang vektor ciri sebagaimana disajikan pada Tabel 2.

Tabel 2. Skenario Reduksi Ciri

Skenario Reduksi Ciri	Ciri atau prediktor
A	skewness - mobility
B	skewness - complexity
C	kurtosis - mobility
D	kurtosis - complexity
E	entropy - mobility
F	entropy - complexity

Tabel 3. Hasil Uji Performa dalam Skenario Reduksi Jumlah Ciri

Skenario	Classifier		CV	Akurasi (%)	Skenario	Classifier		CV	Akurasi (%)
A	SVM	Linear	5	97,4	D	SVM	Linear	5	92,6
		RBF		94,7			RBF		92,6
		Polinomial		94,7			Polinomial		94,6
		Linear	10	98,7			Linear	10	91,9
		RBF		94			RBF		94
		Polinomial		94,7			Polinomial		94
	k-NN	k=1	5	98,7		k-NN	k=1	5	99,3
		k=3		98,7			k=3		98,7
		k=5		98			k=5		98
		k=1	10	97,4			k=1	10	99,3
		k=3		98,7			k=3		97,3
		k=5		98			k=5		98
B	SVM	Linear	5	100	E	SVM	Linear	5	95,3
		RBF		100			RBF		94,6
		Polinomial		99,3			Polinomial		98,7
		Linear	10	100			Linear	10	95,4
		RBF		100			RBF		96
		Polinomial		99,3			Polinomial		98,7
	k-NN	k=1	5	100		k-NN	k=1	5	97,3
		k=3		100			k=3		96
		k=5		100			k=5		96
		k=1	10	100			k=1	10	97,4
		k=3		100			k=3		97,4
		k=5		100			k=5		96
C	SVM	Linear	5	84,8	F	SVM	Linear	5	93,2
		RBF		85,6			RBF		94,6
		Polinomial		91,9			Polinomial		96,2
		Linear	10	86,3			Linear	10	93,2
		RBF		86,3			RBF		96,7
		Polinomial		91,9			Polinomial		96
	k-NN	k=1	5	91,3		k-NN	k=1	5	96,7
		k=3		90			k=3		96,7
		k=5		90,7			k=5		96,7
		k=1	10	92			k=1	10	96,7
		k=3		91,3			k=3		96,7
		k=5		90,7			k=5		97,3

Tabel 4. Perbandingan dengan Studi Sebelumnya

Studi	Metode	Jumlah Ciri	Akurasi (%)
(Rizal & Suryani, 2008)	Dekomposisi paket wavelet, K-means	32	94,4
(Hadiyoso & Rizal, 2017)	Multiskala complexity, K-NN/MLP	5	94
(Estananto, 2018)	Renyi Entropy, SVM	3	100
Studi ini	Statistik, Hjorth, SVM + K-NN	2	100

Tabel 3 menyajikan hasil uji performa untuk masing-masing skenario yang diusulkan. Hasil uji performa sistem dengan mereduksi ciri memberikan akurasi 100% dicapai oleh skenario B. Nilai akurasi yang dihasilkan oleh skenario B ini sama dengan Tabel 1 dimana seluruh ciri sebagai prediktor. Dengan dua ciri yaitu *skewness* dan *complexity*, metode yang diusulkan mampu menghasilkan akurasi terbaik 100%. Studi ini berhasil mengungguli studi yang diusulkan sebelumnya **(Rizal & Suryani, 2008) (Hadiyoso & Rizal, 2017) (Estananto, 2018)**, dalam hal jumlah ciri yang digunakan dan akurasi. Ringkasan perbandingan studi disajikan pada Tabel 4. Jika usulan sistem ini diaplikasikan maka k-NN lebih dipilih dengan mempertimbangkan sumber daya memori dan kompleksitas algoritma. Nilai $k = 1$ dapat menjadi pilihan terbaik jika diinginkan sumber daya paling sederhana.

4. KESIMPULAN

Pada penelitian ini telah berhasil dibuat sebuah sistem untuk klasifikasi sinyal EKG menggunakan pendekatan ciri statistik dan Hjorth parameter. Sinyal EKG yang diklasifikasikan terdiri dari *Normal Sinus Rythim* (NSR), *Congestive Heart Failure* (CHF), dan *Atrial Fibrillation* (AF). Ekstraksi ciri statistik dan Hjorth memberikan nilai perbedaan antar kelas signifikan dan nilai overlap yang rendah. Dalam menguji kekokohan usulan metode, dilakukan validasi performa menggunakan SVM dan k-NN yang dikombinasikan dengan 5-CV dan 10-CV. Skenario lainnya adalah penggunaan seluruh ciri dan pemilihan ciri sebagai prediktor. Hasil pengujian menggunakan semua ciri sebagai prediktor menunjukkan bahwa usulan sistem mampu memberikan akurasi 100%. Hasil ini dicapai menggunakan k-NN untuk semua nilai k dan SVM dengan kernel linier dan RBF. Sementara itu pada skenario reduksi ciri dimana hanya dua ciri yaitu *skewness* dan *complexity*, sistem masih dapat memberikan akurasi klasifikasi 100%. Studi komparasi dengan beberapa studi sebelumnya menunjukkan bahwa usulan metode lebih unggul dalam hal akurasi deteksi dan jumlah ciri yang digunakan. Usulan metode ini diharapkan dapat digunakan untuk data EKG yang lebih besar dan jumlah kelas yang lebih banyak. Pada masa mendatang dapat diaplikasi untuk deteksi otomatis sehingga dapat membantu diagnosa klinis.

DAFTAR RUJUKAN

- Abbaszadeh, B., Haddad, T. dan Yagoub, M. C. E. (2019). Probabilistic prediction of Epileptic Seizures using SVM. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 3442–3445. doi: 10.1109/EMBC.2019.8856286.
- Abo-Zahhad, M., Ahmed, S. M. dan Abbas, S. N. (2014). Biometric authentication based on PCG and ECG signals: Present status and future directions. *Signal, Image and Video Processing*, 8(4), 739–751. doi: 10.1007/s11760-013-0593-4.
- Agrawal, S. dan Gupta, A. (2013). Fractal and EMD based removal of baseline wander and powerline interference from ECG signals. *Computers in Biology and Medicine*, 43(11), 1889–1899. doi: 10.1016/j.compbiomed.2013.07.030.
- Al-khatib, S. M., Lapointe, N. A. dan Chatterjee, R. (2013). Treatment of Atrial. *Comparative Effectiveness Review*, (119).
- Alickovic, E., Kevric, J. dan Subasi, A. (2018). Performance evaluation of empirical mode decomposition, discrete wavelet transform, and wavelet packed decomposition for automated epileptic seizure detection and prediction. *Biomedical Signal Processing and Control*, 39, 94–102. doi: 10.1016/j.bspc.2017.07.022.
- Bavkar, S., Iyer, B. dan Deosarkar, S. (2019). Detection of Alcoholism: An EEG Hybrid Features and Ensemble Subspace K-NN Based Approach. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Springer International Publishing, 161–168. doi: 10.1007/978-3-030-05366-6_13.
- Chen, Y. dkk. (2013). ECG quality evaluation based on wavelet multi-scale entropy. *Journal of Theoretical and Applied Information Technology*, 48(1), 254–259.
- Cortes, C. dan Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. doi: 10.1007/BF00994018.
- Esmael, B., Fruhwirth, R. K. dan Thonhauser, G. (2013). A Statistical Features Based Approach for Operations Recognition. *Drilling Time Series*, 5, 4545.
- Estananto, N. (2018). Klasifikasi Sinyal Elektrokardiogram Menggunakan Renyi Entropy. *Jurnal Elektro dan Mesin Terapan*, 4(2), 11–18. doi: 10.35143/elementer.v4i2.2139.
- Gacek, A. dan Pedrycz, W. (2012). ECG Signal Processing, Classification, and Interpretation: A comprehensive framework of Computational Intelligence. Springer London.
- Hadiyoso, S. dan Rizal, A. (2017). Electrocardiogram signal classification using higher-order complexity of hjorth descriptor. *Advanced Science Letters*, 23(5), 3972–3974. doi:

- 10.1166/asl.2017.8251.
- Hagiwara, Y. dkk. (2018). Computer-aided diagnosis of atrial fibrillation based on ECG Signals: A review, *Information Sciences*, 467, 99–114. doi: 10.1016/j.ins.2018.07.063.
- Hjorth, B. (1970). EEG analysis based on time domain properties. *Electroencephalography and Clinical Neurophysiology*, 29(3), 306–310. doi: 10.1016/0013-4694(70)90143-4.
- Hjorth, B. (1973). The physical significance of time domain descriptors in EEG analysis. *Electroencephalography and Clinical Neurophysiology*, 34(3), 321–325. doi: 10.1016/0013-4694(73)90260-5.
- Joy, R., Acharya, U. R. dan Choo, L. (2013). ECG beat classification using PCA , LDA , ICA and Discrete Wavelet Transform. *Biomedical Signal Processing and Control*, 8(5), 437–448. doi: 10.1016/j.bspc.2013.01.005.
- Kærgaard, K., Jensen, S. H. dan Puthusserypady, S. (2016). A comprehensive performance analysis of EEMD-BLMS and DWT-NN hybrid algorithms for ECG denoising. *Biomedical Signal Processing and Control*, 25, 178–187. doi: 10.1016/j.bspc.2015.11.012.
- Luo, S. dan Johnston, P. (2010). A review of electrocardiogram filtering. *Journal of Electrocardiology*, 43(6), 486–496. doi: 10.1016/j.jelectrocard.2010.07.007.
- Mercy Cleetus, H. M. dan Singh, D. (2014). Multifractal application on electrocardiogram', *Journal of Medical Engineering & Technology*, 38(1), 55–61. doi: 10.3109/03091902.2013.849298.
- Pal, S. dan Mitra, M. (2012). Empirical mode decomposition based ECG enhancement and QRS detection. *Computers in Biology and Medicine*, 42(1), pp. 83–92. doi: 10.1016/j.compbiomed.2011.10.012.
- Patil, A., Deshmukh, C. dan Panat, A. R. (2016). Feature extraction of EEG for emotion recognition using Hjorth features and higher order crossings. *2016 Conference on Advances in Signal Processing (CASP)*. IEEE, (pp. 429–434). doi: 10.1109/CASP.2016.7746209.
- Physionet.org (2010) *ECG Database*.
- Pratiwi, D. A., Rizal, A. dan Magdalena, R. (2020). 'Aplikasi Stockwell Transforms dan K-Nearest Neighbor untuk Klasifikasi Sinyal Elektrokardiogram. *AITI: Jurnal Teknologi Informasi*, 17(1), 22–32.
- Rizal, A. dan Suryani, V. (2008). Pengenalan Signal EKG Menggunakan Dekomposisi Paket Wavelet dan K-Means Clustering. *Proceeding Seminar Nasional Aplikasi Teknologi Inofrmasi 2008(SNATI 2008)*, (pp. 5–8).
- Rizal, A. dan Wijayanto, I. (2019). Classification of premature ventricular contraction based on

- ECG signal using multiorder rényi entropy. *Proceeding - 2019 International Conference of Artificial Intelligence and Information Technology, ICAIIT 2019*, (pp. 225–229). doi: 10.1109/ICAIT.2019.8834590.
- Ruiz-Padial, E. dan Ibáñez-Molina, A. J. (2018). Fractal dimension of EEG signals and heart dynamics in discrete emotional states. *Biological Psychology*, 137, 42–48. doi: 10.1016/j.biopsycho.2018.06.008.
- Schuster, J. L. dkk. (2002). *Living with Advanced Congestive Heart Failure: A Guide for Family Caregivers*.
- Suyanto. (2018). *Machine Learning Tingkat Dasar dan Lanjut*. Informatika Bandung.