

Efek Transformasi Wavelet Diskrit Pada Klasifikasi Aritmia Dari Data Elektrokardiogram Menggunakan Machine Learning

by Nawar Addai Kassab Al-Maliki

Submission date: 20-Jun-2024 01:23PM (UTC+0300)

Submission ID: 2405701029

File name: 4859-16105-1-PB.pdf (727.23K)

Word count: 4981

Character count: 28469



Efek Transformasi Wavelet Diskrit Pada Klasifikasi Aritmia Dari Data Elektrokardiogram Menggunakan Machine Learning

Dodon Turianto Nugrahadi¹, Tri Mulyani, Dwi Kartini, Rudy Herteno, Mohammad Reza Faisal, Irwan Budiman, Friska Abadi

Ilmu Komputer, Universitas Lambung Mangkurat, Banjarbaru, Indonesia

Email: ¹dodonturianto@ulm.ac.id, ²trimlyani60@gmail.com, ³dwikartini@ulm.ac.id, ⁴rudy.herteno@ulm.ac.id,

⁵reza.faisal@ulm.ac.id, ⁶irwan.budiman@ulm.ac.id, ⁷friska.abadi@ulm.ac.id

Email Penulis Korespondensi: dodonturianto@ulm.ac.id

Abstrak—Aritmia merupakan salah satu penyakit kelainan pada irama jantung dan beberapa pasien yang menderita aritmia tidak merasakan gejala apapun, maka perlu adanya otomatisasi deteksi dini untuk aritmia dengan menggunakan elektrokardiogram. Penelitian yang ada telah melakukan klasifikasi dengan beberapa metode data mining. Pada penelitian ini transformasi untuk pemrosesan sinyal menggunakan Discrete Wavelet Transform dimana terjadi proses filterisasi yang memisahkan sebuah sinyal menjadi sinyal berfrekuensi tinggi dan rendah tanpa menghilangkan informasi dari sinyal dan dilakukan dengan dekomposisi dua tingkat. Selanjutnya dilakukan normalisasi data menggunakan min-max normalization lalu dimasukkan ke dalam model klasifikasi menggunakan metode Support Vector Machine dengan kernel Gaussian Radial Basis Function dengan Naive Bayes dan K-Nearest Neighbor. Data yang digunakan masing-masing berjumlah 140 data dengan masing-masing 35 data untuk setiap labelnya. Pada penelitian ini menunjukkan hasil pada dekomposisi level 1 didapatkan akurasi tertinggi pada db7 untuk klasifikasi Support Vector Machine menghasilkan akurasi 73,57%, Naive Bayes 68,57%, K-Nearest Neighbor dengan k=3 menghasilkan akurasi 59,64%, K-Nearest Neighbor dengan k=5 menghasilkan akurasi 63,57% sedangkan pada level 2 didapatkan akurasi tertinggi pada db6 dan db8 dengan model klasifikasi untuk Support Vector Machine menghasilkan akurasi 70,71%, Naive Bayes 67,50%, K-Nearest Neighbor k=3 menghasilkan akurasi 66,07%, K-Nearest Neighbor dengan k=5 menghasilkan akurasi 65%. Disimpulkan bahwa akurasi tertinggi dihasilkan oleh dekomposisi level 1 dengan klasifikasi Support Vector Machine serta menunjukkan bahwa jenis wavelet Daubechies memiliki hasil yang lebih baik dibandingkan wavelet Haar.

Kata Kunci: Elektrokardiogram; Transformasi Wavelet Diskrit; Support Vector Machine; K-Nearest Neighbor; Naive Bayes

Abstract—Arrhythmia is one of the abnormalities of the heart rhythm, and some patients who suffer from arrhythmia do not feel any symptoms. Automating the early detection of arrhythmia is necessary by using an electrocardiogram. Previous research that had been done conducted classifications using several methods of data mining. In this research, the transformation for processing signals used is Discrete Wavelet Transformation, where a filtering process occurs that separates signals into high and low-frequency signals without losing the information from signals and is carried out with a two-level decomposition. After that, data normalization was performed using min-max normalization and was put into the model classification using the Support Vector Machine method with a Gaussian Radial Basis Function kernel of Naive Bayes and K-Nearest Neighbor. Each data that was being used consisted of 140 data with a total of 35 data for each label. This research shows that at level 1 decomposition, the highest accuracy was obtained at db7 for the classification using Support Vector Machine with an accuracy of 73.57%, 68.57% for Naive Bayes, K-Nearest Neighbor with k=3 resulting in an accuracy of 59.64%, and K-Nearest Neighbor with k=5 resulting in an accuracy of 63.57% while at level 2 decomposition the highest accuracy was obtained at db6 and db8 for the classification using Support Vector Machine with an accuracy of 70.71%, 67.50% for Naive Bayes, K-Nearest Neighbor with k=3 resulting in an accuracy of 66.07%, and K-Nearest Neighbor with k=5 resulting in an accuracy of 65%. From this research, it can be concluded that the highest accuracy is produced by decomposition level 1 using Support Vector Machine classification and that the Daubechies wavelet type has better results than the Haar wavelet.

Keywords: Electrocardiogram; Discrete Wavelet Transform; Support Vector Machine; K-Nearest Neighbor; Naive Bayes

1. PENDAHULUAN

Aritmia merupakan salah satu penyakit kelainan terhadap irama jantung. Oleh karena itu beberapa pasien yang menderita aritmia tidak merasakan gejala apapun, maka perlu adanya otomatisasi deteksi dini untuk aritmia dengan menggunakan elektrokardiogram. Elektrokardiogram merupakan instrumen medis yang digunakan sebagai alat untuk memperoleh informasi kerja jantung manusia. Pada era ini pemrosesan sinyal jantung dalam dunia kedokteran menjadi hal yang penting untuk membantu dokter dalam membuat keputusan. Analisis deteksi kelainan jantung yang umum dilakukan dalam dunia kesehatan yaitu dengan melihat grafik rekaman EKG secara manual. Adapun jenis-jenis aritmia didalam penelitian ini yaitu Atrial Fibrillation, PVC Bigeminy atau Premature ventricular contraction (PVC) dan Ventricular Tachycardi[1]. Dalam riset klasifikasi penyakit jantung terdapat dua perlakuan terhadap data EKG. Perlakuan pertama adalah dengan menggunakan data EKG mentah seperti yang dilakukan pada penelitian [2]. Pada penelitian ini data EKG mentah yang diseleksi kemudian diklasifikasi dengan metode klasifikasi tipe shallow learning yaitu SVM. Perlakuan kedua adalah dengan melakukan analisis sinyal EKG mentah dengan melakukan transformasi terhadap sinyal tersebut. Salah satu teknik transformasi yang digunakan adalah transformasi wavelet[3].

Transformasi wavelet merupakan teknik dekomposisi multiresolusi untuk mengatasi masalah pemodelan yang menghasilkan penggambaran sinyal yang baik pada domain waktu dan domain frekuensi[4]. Transformasi wavelet untuk pemrosesan sinyal pada penelitian ini yaitu Discrete Wavelet Transform dimana terjadi proses



filterisasi yang memisahkan sebuah sinyal menjadi sinyal berfrekuensi tinggi dan rendah tanpa menghilangkan informasi dari sinyal.

Pada penelitian Tandyo, dkk. yang menerapkan metode Discrete Wavelet Transform (DWT) dengan level tujuh dekomposisi wavelet optimal meningkatkan akurasi dan transformasi wavelet diskrit mampu memperkecil pengaruh yang disebabkan oleh noise pada sinyal suara input[5]. Pada penelitian Belkacemi, dkk. yang menerapkan penggunaan metode Discrete Wavelet Transform pada data bentuk sinyal pelumasan bantalan motor induksi yang tidak benar dengan delapan tingkat dekomposisi sinyal wavelet menunjukkan untuk medium kecepatan prosedur dekomposisi Discrete Wavelet Transform efisien untuk deteksi bantalan berpelumas yang tidak tepat. Oleh karena itu, gelombang koefisien aproksimasi dan detail dapat dengan mudah digunakan untuk deteksi cacat pelumasan[6].


Setelah sinyal melewati proses transformasi menggunakan Discrete Wavelet Transform maka dilakukan proses pengambilan keputusan. Beberapa penelitian yang dilakukan untuk memanfaatkan machine learning dalam membantu diagnosa aritmia. Pada penelitian sebelumnya tentang klasifikasi aritmia berdasarkan hasil elektrokardiogram telah dilakukan salah satunya oleh Deepak & Wijayakumar dimana mengimplementasikan kerangka klasifikasi sinyal yang diterapkan pada basis data sinyal EKG MIT-BIH untuk menilai kinerja deteksi dengan metode K-Nearest Neighbor yang menghasilkan akurasi sebesar 94,29%[7]. Pada penelitian Ramadhan, dkk. dengan menggunakan metode Local Features yang merupakan metode ekstraksi ciri dan proses klasifikasi yang dilakukan oleh Support Vector Machine. Dalam fitur pengklasifikasian yang dilakukan oleh Support Vector Machine mendapatkan hasil akurasi dari dua dataset yang digunakan. Untuk data elektrokardiogram normal akurasi terbesar bernilai 67% yang dihasilkan dari Support Vector Machine. kernel linear dan RBF, untuk data elektrokardiogram aritmia akurasi terbesar bernilai 83% yang dihasilkan oleh kernel linear dan 16% menggunakan kernel RBF[8]. Pada penelitian Marianto (2020) yaitu klasifikasi sinyal palsu pada indicator stochastic oscillator menggunakan metode Naive Bayes menghasilkan akurasi sebesar 76,92%[9].

Berdasarkan penjelasan yang telah diuraikan diatas maka penelitian ini ingin menentukan kinerja terbaik antara algoritma Support Vector Machine, K-Nearest Neighbor dan Naive Bayes dalam proses klasifikasi serta kinerja terbaik antara dekomposisi level 1 atau level 2 pada metode transformasi wavelet diskrit untuk proses filtering sinyal elektrokardiogram.

2. METODOLOGI PENELITIAN

2.1 Dataset

Dataset yang digunakan dalam penelitian ini diambil dari penelitian sebelumnya oleh Reiza yang bisa di unduh pada repositori Github <https://github.com/auralord/skripsi-ekg.git>. Jumlah data yang digunakan sebanyak 140 data yang terdiri dari 35 data Normal, 35 data Atrial Fibrillation, 35 data PVC Bigeminy, dan 35 Ventricular Tachycardia. Masing-masing kelas memiliki 2160 fitur dengan durasi 6 detik.



Gambar 1. Visualisasi EKG (a) Normal (b) Atrial Fibrillation (c) PVC Bigeminy (d) Ventricular Tachycardia

- (a) Detak jantung normal atau normal sinus rhythm menunjukkan detak jantung yang tidak memiliki aritmia serta ritme atria dan ventrikelnya teratur
- (b) Atrial fibrillation (Afib) adalah aktivitas listrik yang sangat tidak teratur pada jaringan atria
- (c) Premature ventricular contraction (PVC) adalah detak abnormal yang disebabkan bertambahnya sensitivitas pada sistem konduksi atau jaringan otot ventrikel.



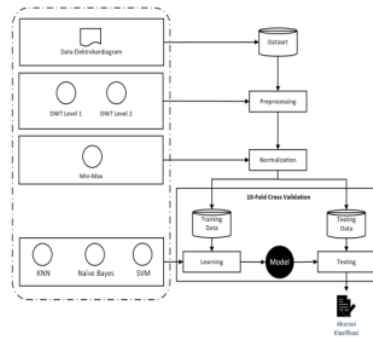
(d) Ventricular Tachycardia (VT) terjadi saat tiga atau lebih PVC dan terjadi secara berurutan menyebabkan jantung berdetak sangat cepat.

Tabel 1. Dataset Sinyal Elektrokardiogram

No	Kelas	Jumlah	Jumlah Data
1	Normal	2160	35
2	Atrial Fibrillation	2160	35
3	PVC Bigeminy	2160	35
4	Ventricular Tachicardia	2160	35
Total			140

2.2 Metode Penelitian


Langkah pertama yaitu melakukan transformasi data dengan transformasi wavelet pada sinyal elektrokardiogram. Pada proses transformasi akan dilakukan dekomposisi sinyal dan proses filterisasi dengan melewati highpass filter dan lowpass filter. Data yang dihasilkan dari proses dekomposisi akan dinormalisasi menggunakan min-max normalization. Kemudian data akan diproses ke dalam tiga model klasifikasi dengan menggunakan metode Support Vector Machine, K-Nearest Neighbor dan Naive Bayes. Hasil eksperimen tersebut akan dimasukkan dalam laporan dan menghasilkan perbandingan pada akurasi model klasifikasi.



Gambar 2. Langkah Penelitian

2.3 Transformasi Wavelet Diskrit

Proses pertama yang dilakukan yaitu melakukan transformasi data elektrokardiogram. Discrete Wavelet Transform digunakan untuk mengubah data menjadi bentuk skala dan melakukan proses filtering data tanpa mengubah informasi sinyal elektrokardiogram. Sinyal akan dilewatkan pada rangkaian filter high pass dan low pass, kemudian setengah dari masing-masing keluaran diambil sebagai contoh melalui sub sampling[10]. Proses ini merupakan proses dekomposisi satu tingkat. Keluaran dari filter low pass digunakan untuk masukan pada proses tingkat berikutnya. Dalam penelitian ini digunakan dua jenis transformasi wavelet yaitu wavelet haar dan Daubechies. Wavelet Daubechies adalah pengembangan dari wavelet Haar. Daubechies 1 (db1) dengan panjang filter 2 merupakan wavelet Haar. Daubechies 2 disingkat (db2) adalah wavelet Daubechies dengan banyak filter 4 yang db3 adalah wavelet Daubechies dengan banyak filter 6 dan seterusnya[11]. Tingkat dekomposisi wavelet yang digunakan dalam penelitian ini adalah 2 level yang ditunjukkan pada gambar 3[12].



Gambar 3. Dekomposisi Wavelet

2.4 Min Max Normalization

Min-Max normalization merupakan metode normalisasi dengan melakukan transformasi linier terhadap data asli sehingga menghasilkan keseimbangan nilai perbandingan antar data saat sebelum dan sesudah proses[13]. Metode ini dapat menggunakan rumus sebagai berikut:



$$\text{Normalized } (x) = \frac{\text{minRange} + (x - \text{minValue})(\text{maxRange} - \text{minRange})}{\text{maxValue} - \text{minValue}} \quad (1)$$

2.5 Cross Validation

Cross validation merupakan prosedur acak yang membagi kumpulan data menjadi K yang terputus-putus dengan ukuran yang kira-kira sama, dan setiap lipatan digunakan secara bergantian untuk menguji model yang diinduksi dari lipatan K-1 lainnya oleh algoritma klasifikasi [14], [15]. Menurut Fu, k-Fold Cross Validation mengulang k-kali untuk membagi sebuah himpunan contoh secara acak menjadi k subset yang saling bebas, setiap ulangan disisakan satu subset untuk pengujian dan subset lainnya untuk pelatihan [16][17]. Pada penelitian ini menggunakan K-fold cross validation dengan k = 10.

2.6 Support Vector Machine

Support Vector Machine adalah sistem pembelajaran yang menggunakan ruang hipotesis berupa fungsi-fungsi linier dalam sebuah ruang fitur (feature space) berdimensi tinggi, dilatih dengan algoritma pembelajaran yang didasarkan pada teori optimasi dengan mengimplementasikan learning bias yang berasal dari teori pembelajaran statistik [18]. Ide dasar dari SVM adalah memaksimalkan batas hyperplane. Hyperplane adalah garis pemisah terbaik antara kelas. Hyperplane dapat ditemukan dengan cara menghitung margin hyperplane dan mencari titik maksimalnya. Margin adalah jarak antara hyperplane dengan data terdekat dari masing-masing kelas. Data yang paling dekat biasa disebut dengan Support Vector [19], [20]. Pada penelitian ini menggunakan bahasa pemrograman python dengan library OneVsOneClassifier serta kernel Radial Basis Function (RBF) dan parameter default (Cost C = 1).

2.7 K-Nearest Neighbor

K-Nearest Neighbor adalah metode untuk melakukan klasifikasi terhadap objek berdasarkan data pembelajaran yang jaraknya paling dekat atau memiliki persamaan ciri paling banyak dengan objek tersebut [21], [22]. K-Nearest Neighbor termasuk algoritma supervised learning dimana hasil dari query instance yang baru diklasifikasikan berdasarkan mayoritas dari kategori pada k-NN. Kelas yang paling banyak muncul itu yang akan menjadi kelas hasil klasifikasi [17]. Dalam penelitian ini menggunakan K-Nearest Neighbor dengan parameter k=3 dan k=5.

2.8 Naive Bayes

Naive Bayes merupakan klasifikasi sederhana berdasarkan aplikasi teorema Bayes dengan asumsi antar variable penjelas saling bebas (independen) yaitu kehadiran atau ketiadaan dari suatu kejadian tertentu dari suatu kelompok tidak berhubungan dengan kehadiran atau ketiadaan dari kejadian lainnya [23]. Algoritma Naive Bayes memprediksi peluang di masa depan berdasarkan pengalaman di masa sebelumnya sehingga dikenal sebagai Teorema Bayes [24]. Model yang digunakan pada penelitian ini menggunakan model Gaussian Naive Bayes.

2.9 Confusion Matrix

Confusion matrix merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi. Pada dasarnya confusion matrix mengandung informasi yang membandingkan hasil klasifikasi yang dilakukan sistem dengan hasil klasifikasi yang seharusnya [25].

3. HASIL DAN PEMBAHASAN

3.1 Hasil Penelitian

Pada bagian ini penulis menjelaskan hasil penelitian terkait analisis penelitian data elektrokardiogram menggunakan metode Transformasi Wavelet Diskrit dengan algoritma klasifikasi Support Vector Machine, Naive Bayes, dan K-Nearest Neighbor

3.1.1 Transformasi Wavelet Diskrit

Transformasi Wavelet Diskrit yang berfungsi untuk melakukan proses filtering data tanpa mengubah informasi sinyal EKG dan mengubah data menjadi low pass filter dan high pass filter. Dapat dilihat pada gambar 4 dan tabel 2 contoh hasil transformasi data menggunakan transformasi wavelet diskrit.



Gambar 4. Visualisasi Data EKG (a) Hasil Transformasi Level 1 dan (b) Hasil Transformasi Level 2




Tabel 2. Hasil Transformasi Data

Level	db	Feature	Level	db	Feature
1	db1	2.160	2	db1	1.080
	db2	2.162		db2	1.084
	db3	2.164		db3	1.086
	db4	2.166		db4	1.090
	db5	2.168		db5	1.092
	db6	2.170		db6	1.096
	db7	2.172		db7	1.098
	db8	2.174		db8	1.102
	db9	2.176		db9	1.104
	db10	2.178		db10	1.108

3.1.2 Min Max Normalization

Berikut ini hasil proses normalisasi data menggunakan Min-Max yang ditunjukkan pada gambar 10.



Gambar 5. Visualisasi Data EKG (a) menunjukkan hasil normalisasi data level 1 dan (b) menunjukkan hasil normalisasi data level 2

3.1.3 Klasifikasi

1. Support Vector Machine

Hasil kinerja Support Vector Machine pada dekomposisi level 1 dan level 2 berupa akurasi pada klasifikasi aritmia berdasarkan hasil elektrokardiogram dengan transformasi wavelet diskrit ditunjukkan pada tabel 3.

Tabel 3. Hasil Akurasi Support Vector Machine

Level	db	Akurasi	Level	db	Akurasi
1	db1	67.86%	2	db1	68.21%
	db2	70.71%		db2	68.93%
	db3	70.71%		db3	69.64%
	db4	72.14%		db4	69.64%
	db5	72.50%		db5	68.93%
	db6	73.21%		db6	70.71%
	db7	73.57%		db7	69.29%
	db8	72.50%		db8	70.71%
	db9	72.50%		db9	70.00%
	db10	72.14%		db10	69.64%

2. K-Nearest Neighbor

Hasil kinerja K-Nearest Neighbor menggunakan nilai parameter k=3 dan k=5 pada dekomposisi level 1 dan level 2 berupa akurasi pada klasifikasi aritmia berdasarkan hasil elektrokardiogram dengan transformasi wavelet diskrit ditunjukkan pada tabel 4.

Tabel 4. Hasil Akurasi K-Nearest Neighbor

K-Nearest Neighbor k-3			K-Nearest Neighbor k-5								
Level	db	Akurasi	Level	db	Akurasi	Level	db	Akurasi	Level	db	Akurasi
1	db1	65.71%	2	db1	65.36%	1	db1	65.71%	2	db1	64.64%
	db2	63.93%		db2	65.00%		db2	64.29%		db2	65.36%
	db3	64.29%		db3	63.21%		db3	65.71%		db3	63.93%
	db4	61.43%		db4	63.57%		db4	63.57%		db4	65.00%
	db5	59.64%		db5	66.43%		db5	64.29%		db5	66.43%
	db6	59.64%		db6	62.14%		db6	63.57%		db6	65.36%
	db7	61.07%		db7	64.64%		db7	63.21%		db7	63.57%
	db8	61.79%		db8	66.07%		db8	62.86%		db8	65.00%
	db9	62.86%		db9	63.93%		db9	63.21%		db9	67.14%
	db10	62.86%		db10	63.21%		db10	63.21%		db10	65.36%



3. Naive Bayes

Hasil kinerja kinerja Naive Bayes pada dekomposisi level 1 dan level 2 berupa akurasi pada klasifikasi aritmia berdasarkan hasil elektrokardiogram dengan transformasi wavelet diskrit ditunjukkan pada tabel 5.

Tabel 5. Hasil Akurasi Naive Bayes

Level	db	Akurasi	Level	db	Akurasi
1	db1	65.36%	2	db1	66.07%
	db2	66.79%		db2	67.50%
	db3	67.86%		db3	67.50%
	db4	67.86%		db4	66.79%
	db5	68.21%		db5	69.29%
	db6	68.57%		db6	67.50%
	db7	69.29%		db7	68.21%
	db8	70.00%		db8	67.50%
	db9	69.64%		db9	69.29%
	db10	69.29%		db10	67.86%

3.2 Pembahasan

Berikut ini hasil penelitian pada dekomposisi level 1 menggunakan titik filter db1, db2, db3, db4, db5, db6, db7, db8, db9, dan db10 memiliki hasil akurasi yang bervariasi tiap jenis wavelet. Hasil klasifikasi menggunakan ketiga model klasifikasi ditampilkan pada tabel 6.

Tabel 6. Hasil Akurasi Level 1

DB	Support Vector Machine	Naive Bayes	K-Nearest Neighbor k=3	K-Nearest Neighbor k=3
	Akurasi	Akurasi	Akurasi	Akurasi
db1	67.86%	65.36%	65.71%	65.71%
db2	70.71%	66.79%	63.93%	64.29%
db3	70.71%	67.86%	64.29%	65.71%
db4	72.14%	67.86%	61.43%	63.57%
db5	72.50%	68.21%	59.64%	64.29%
db6	73.21%	68.57%	59.64%	63.57%
db7	73.57%	69.29%	61.07%	63.21%
db8	72.50%	70.00%	61.79%	62.86%
db9	72.50%	69.64%	62.86%	63.21%
db10	72.14%	69.29%	62.86%	63.21%

Berdasarkan tabel 6 pada model klasifikasi Support Vector Machine menggunakan db1 hingga db10 nilai tertinggi didapatkan pada db7 dengan akurasi sebesar 73,57% dan untuk hasil terendah yaitu db1 dengan akurasi sebesar 67,86%. Pada model klasifikasi Naive Bayes menggunakan db1 hingga db10 nilai tertinggi didapatkan pada db8 dengan akurasi sebesar 70% dan untuk hasil terendah yaitu db1 dengan akurasi sebesar 65,36. Pada model klasifikasi K-Nearest Neighbor dengan parameter k 3 dan k 5 menggunakan db1 hingga db10 nilai tertinggi didapatkan pada db1 dan db3 dengan akurasi sebesar 65,71% dan untuk hasil terendah yaitu k 3 pada db5 dan db6 dengan akurasi sebesar 59,64. Berikut ini hasil confusion matrix dari dekomposisi level 1 pada klasifikasi Support Vector Machine yang ditunjukkan pada tabel 7.

Tabel 7. Confusion Matrix Level 1

Prediksi	Aktual			
	Normal	AT	PVC	VT
Normal	9	16	10	0
AT	5	19	7	4
PVC	1	16	13	5
VT	1	6	3	25

Confusion matrix dari hasil klasifikasi Support Vector Machine yang disajikan pada tabel 7 terdapat 9 data kelas normal, 19 data kelas atrial fibrillation, 13 data kelas pvc bigeminy dan 25 data kelas ventricular techycardia yang terklasifikasi dengan benar. Berdasarkan hasil evaluasi tersebut, untuk kelas normal mendapatkan hasil akurasi sebesar 76.43%, kelas atrial fibrillation 61.43%, kelas pvc bigeminy 70%, kelas ventricular techycardia 86.43%. Dari hasil tersebut, kelas ventricular techycardia memiliki prediksi kelas paling tinggi.

Berikut ini hasil penelitian pada dekomposisi level 2 menggunakan titik filter db1, db2, db3, db4, db5, db6, db7, db8, db9, dan db10 memiliki hasil akurasi yang bervariasi tiap jenis wavelet. Hasil klasifikasi menggunakan ketiga model klasifikasi ditampilkan pada tabel 8.



Tabel 8. Hasil Akurasi Level 2

DB	Support Vector Machine	Naive Bayes	K-Nearest Neighbor k=3	K-Nearest Neighbor k=5
	Akurasi	Akurasi	Akurasi	Akurasi
db1	68.21%	66.07%	65.36%	64.64%
db2	68.93%	67.50%	65.00%	65.36%
db3	69.64%	67.50%	63.21%	63.93%
db4	69.64%	66.79%	63.57%	65.00%
db5	68.93%	69.29%	66.43%	66.43%
db6	70.71%	67.50%	62.14%	65.36%
db7	69.29%	68.21%	64.64%	63.57%
db8	70.71%	67.50%	66.07%	65.00%
db9	70.00%	69.29%	63.93%	67.14%
db10	69.64%	67.86%	63.21%	65.36%


Berdasarkan tabel 8 pada model klasifikasi Support Vector Machine menggunakan db1 hingga db10 nilai tertinggi didapatkan pada db6 dan db8 dengan akurasi sebesar 70,71% dan untuk hasil terendah yaitu db1 dengan akurasi sebesar 68,21%. Pada model klasifikasi Naive Bayes menggunakan db1 hingga db10 nilai tertinggi didapatkan pada db5 dan db9 dengan akurasi sebesar 69,29% dan untuk hasil terendah yaitu db1 dengan akurasi sebesar 66,07%. Pada model klasifikasi K-Nearest Neighbor dengan parameter k 3 dan k 5 menggunakan db1 hingga db10 nilai tertinggi didapatkan pada db1 parameter k 5 dengan akurasi sebesar 67,14% dan untuk hasil terendah yaitu db6 parameter k 3 dengan akurasi sebesar 62,14%. Berikut ini hasil confusion matrix dari dekomposisi level 1 pada klasifikasi Support Vector Machine yang ditunjukkan pada tabel 9.

Tabel 9. Confusion Matrix Level 2

Prediksi	Aktual			
	Normal	AT	PVC	VT
Normal	14	11	9	1
AT	13	9	7	6
PVC	8	10	12	5
VT	3	6	3	23


Confusion matrix dari hasil klasifikasi Support Vector Machine yang disajikan pada tabel 9 terdapat 14 data kelas normal, 9 data kelas atrial fibrillation, 12 data kelas pvc bigeminy dan 23 data kelas ventricular techycardia yang terklasifikasi dengan benar. Berdasarkan hasil evaluasi tersebut, untuk kelas normal mendapatkan hasil akurasi sebesar 67,86%, kelas atrial fibrillation 62,14%, kelas pvc bigeminy 70%, kelas ventricular techycardia 82,86%. Dari hasil tersebut, kelas ventricular techycardia memiliki prediksi kelas paling tinggi.

Berikut ini grafik yang menunjukkan perbandingan algoritma Support Vector Machine, Naive Bayes dan K-Nearest Neighbor. Gambar 6 menunjukkan perbandingan klasifikasi pada transformasi dekomposisi 1 dan gambar 7 menunjukkan perbandingan klasifikasi pada transformasi dekomposisi 2.



Gambar 6. Hasil Perbandingan Algoritma Machine Learning Pada Level 1.

Berdasarkan gambar 6 dapat dilihat bahwa algoritma yang paling baik dihasilkan oleh Support Vector Machine dengan akurasi sebesar 73,57%, urutan kedua yaitu algoritma Naive Bayes dengan akurasi sebesar 70% serta K-Nearest Neighbor k 3 memperoleh akurasi sebesar 65,71% dan k 5 memperoleh akurasi sebesar 65,71%.



Gambar 7. Hasil Perbandingan Algoritma Machine Learning Pada Level 1

Berdasarkan gambar 7 dapat dilihat bahwa algoritma yang paling baik dihasilkan oleh Support Vector Machine dengan akurasi sebesar 70,71%, urutan kedua yaitu algoritma Naive Bayes dengan akurasi sebesar 69,29% serta K-Nearest Neighbor k 3 memperoleh akurasi sebesar 66,07% dan k 5 memperoleh akurasi sebesar 66,43%.

25

4. KESIMPULAN

Berdasarkan hasil dari penelitian yang telah dilakukan proses transformasi menggunakan wavelet diskrit mampu mengurangi fitur dan meningkatkan hasil akurasi. Pada percobaan dekomposisi level 1 didapatkan akurasi tertinggi pada db7 dengan model klasifikasi Support Vector Machine menghasilkan akurasi sebesar 73,57%. Pada percobaan dekomposisi level 2 didapatkan akurasi tertinggi pada db6 dan db8 dengan model klasifikasi Support Vector Machine menghasilkan akurasi sebesar 70,71%. Dari dua tingkat dekomposisi yang dilakukan didapatkan bahwa dekomposisi yang memiliki hasil terbaik yaitu dekomposisi satu tingkat atau level 1 serta menunjukkan bahwa jenis wavelet Daubechies memiliki hasil yang lebih baik dibandingkan wavelet haar. Pada penelitian berikutnya bisa dilakukan penelitian lebih lanjut dengan menambahkan dekomposisi level 3 dan seterusnya serta menggunakan algoritma deep learning.

REFERENCES

- [1] R. A. Cahya, C. Dewi, and B. Rahayudi, "Klasifikasi Aritmia Dari Hasil Elektrokardiogram Menggunakan Support Vector Machine Dengan Seleksi Fitur Menggunakan Algoritma Genetika," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, e-ISSN, vol. 2548, p. 964X, 2018.
- [2] R. A. Cahya, C. Dewi, and B. Rahayudi, "Arrhythmia Classification From Electrocardiogram Results Using Support Vector Machine With Feature Selection Using Genetic Algorithms," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2548, p. 964X, 2018.
- [3] T. Wang, C. Lu, Y. Sun, M. Yang, C. Liu, and C. Ou, "Automatic ECG classification using continuous wavelet transform and convolutional neural network," *Entropy*, vol. 23, no. 1, p. 119, 2021.
- [4] B.-L. Zhang and Z.-Y. Dong, "An adaptive neural-wavelet model for short term load forecasting," *Electr. power Syst. Res.*, vol. 59, no. 2, pp. 121–129, 2001.
- [5] A. Tandyo, M. Martono, and A. Widyatmoko, "Speaker Identification Menggunakan Transformasi Wavelet Diskrit Dan Jaringan Saraf Tiruan Back-Propagation," *CommIT (Communication Inf. Technol. J.)*, vol. 2, no. 1, pp. 1–7, 2008.
- [6] B. Belkacemi, S. Saad, Z. Ghemari, F. Zaamouche, and A. Khazzane, "Detection of induction motor improper bearing lubrication by discrete wavelet transforms (DWT) decomposition," *Instrum. Mes. Metrol.*, vol. 19, no. 5, pp. 347–354, Oct. 2020, doi: 10.18280/im.190504.
- [7] H. A. Deepak and T. Vijayakumar, "ECG Signal Classification with Hybrid Features Using Bayesian Optimized K-Nearest Neighbors Classifier," *Int. J. Intell. Eng. Syst.*, vol. 14, no. 6, pp. 50–65, Dec. 2021, doi: 10.22266/ijies2021.1231.06.
- [8] G. T. Ramadhani, A. Adiwijaya, and D. Q. Utama, "Klasifikasi Penyakit Aritmia Melalui Sinyal Elektrokardiogram (ekg) Menggunakan Metode Local Features Dan Support Vector Machine," *eProceedings Eng.*, vol. 5, no. 1, 2018.
- [9] F. Y. Marianto, T. Tarno, and I. M. Di Asih, "Perbandingan Metode Naive Bayes Dan Bayesian Regularization Neural Network (BRNN) Untuk Klasifikasi Sinyal Palsu Pada Indikator Stochastic Oscillator (Studi Kasus: Saham PT Bank Rakyat Indonesia (Persero) Tbk Periode Januari 2017--Agustus 2019)," *J. Gaussian*, vol. 9, no. 1, pp. 16–25, 2020.
- [10] Z. Zhao, W. Chen, X. Wu, P. C. Y. Chen, and J. Liu, "LSTM network: a deep learning approach for short-term traffic forecast," *IET Intell. Transp. Syst.*, vol. 11, no. 2, pp. 68–75, 2017.
- [11] G. Gumilar and others, "Implementasi Transformasi Wavelet Daubechies pada Kompresi Citra Digital," *Cauchy*, vol. 2, no. 4, pp. 211–215, 2013.
- [12] M. Aqil, A. Jbari, and A. Bourouhou, "ECG Signal Denoising by Discrete Wavelet Transform," *Int. J. Online Eng.*, vol. 13, no. 9, 2017.



- [13] D. A. Nasution, H. H. Khotimah, and N. Chamidah, "Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN," *Comput. Eng. Sci. Syst. J.*, vol. 4, no. 1, p. 78, 2019, doi: 10.24114/cess.v4i1.11458.
- [14] T.-T. Wong, "Performance evaluation of classification algorithms by k-fold and leave-one-out cross validation," *Pattern Recognit.*, vol. 48, no. 9, pp. 2839–2846, 2015.
- [15] N. G. Ramadhan and A. Khoirunnisa, "Klasifikasi Data Malaria Menggunakan Metode Support Vector Machine," *J. MEDIA Inform. BUDIDARMA*, vol. 5, no. 4, pp. 1580–1584, 2021.
- [16] L. Fu, *Neural networks in computer intelligence*. McGraw-Hill, Inc., 1994.
- [17] M. A. Banjarsari, I. Budiman, and A. Farmadi, "Penerapan K-Optimal Pada Algoritma Knn Untuk Prediksi Kelulusan Tepat Waktu Mahasiswa Program Studi Ilmu Komputer Fmipa Unlam Berdasarkan Ip Sampai Dengan Semester 4," *Klik-Kumpulan J. Ilmu Komput.*, vol. 2, no. 2, pp. 159–173, 2016.
- [18] R. Munawarah, O. Soesanto, and M. R. Faisal, "Penerapan Metode Support Vector Machine Pada Diagnosa Hepatitis," *KLIK-KUMPULAN J. ILMU Komput.*, vol. 3, no. 1, pp. 103–113, 2016.
- [19] M. Affandes and others, "Penerapan Metode Support Vector Machine (SVM) Menggunakan Kernel Radial Basis Faunction (RBF) Pada Klasifikasi Tweet," *SITEKIN J. Sains, Teknol. dan Ind.*, vol. 12, no. 2, pp. 189–197, 2015.
- [20] D. U. Dewangga, A. Adiwijaya, and D. Q. Utama, "Identifikasi Citra berdasarkan Gigitan Ular menggunakan Metode Active Contour Model dan Support Vector Machine," *J. Media Inform. Budidarma*, vol. 3, no. 4, pp. 299–306, 2019.
- [21] D. Syahid, J. Jumadi, and D. Nursantika, "Sistem Klasifikasi Jenis Tanaman Hias Daun Philodendron Menggunakan Metode K-Nearest Neighbor (KNN) Berdasarkan Nilai Hue, Saturation, Value (HSV)," *J. Online Inform.*, vol. 1, no. 1, pp. 20–23, 2016.
- [22] S. P. Adenugraha, V. Arinal, and D. I. Mulyana, "Klasifikasi Kematangan Buah Pisang Ambon Menggunakan Metode KNN dan PCA Berdasarkan Citra RGB dan HSV," *J. MEDIA Inform. BUDIDARMA*, vol. 6, no. 1, pp. 9–17, 2022.
- [23] Y. Ervinaeni, A. S. Hidayat, and E. Riana, "Sistem Pakar Diagnosa Gangguan Hiperaktif Pada Anak Dengan Metode Naive Bayes Berbasis Web," *J. Media Inform. Budidarma*, vol. 3, no. 2, p. 90, 2019, doi: 10.30865/mib.v3i2.1158.
- [24] L. Lia Regitaningtyas, T. Maharani, and B. Hikmahwan, "Klasifikasi Data Lulusan Siswa Smp Menggunakan Metode Naive Bayes," *Kumpul. J. Ilmu Komput.*, vol. 09, no. 1, pp. 10–21, 2022.
- [25] E. Prasetyo, "Data mining konsep dan aplikasi menggunakan matlab," *Yogyakarta Andi*, vol. 1, 2012.

Efek Transformasi Wavelet Diskrit Pada Klasifikasi Aritmia Dari Data Elektrokardiogram Menggunakan Machine Learning

ORIGINALITY REPORT

19%

SIMILARITY INDEX

15%

INTERNET SOURCES

11%

PUBLICATIONS

5%

STUDENT PAPERS

PRIMARY SOURCES

1	core.ac.uk Internet Source	3%
2	Muhammad Azman Maricar, Dian Pramana. "Perbandingan Akurasi Naïve Bayes dan K-Nearest Neighbor pada Klasifikasi untuk Meramalkan Status Pekerjaan Alumni ITB STIKOM Bali", Jurnal Sistem dan Informatika (JSI), 2019 Publication	1%
3	jurnal.kaputama.ac.id Internet Source	1%
4	Achmad Saiful Rizal, Moch. Lutfi. "PREDIKSI HASIL PEMILU LEGISLATIF MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR BERBASIS BACKWARD ELIMINATION", Jurnal RESISTOR (Rekayasa Sistem Komputer), 2020 Publication	1%
5	adoc.pub Internet Source	1%

6	repository.uin-suska.ac.id Internet Source	1 %
7	123dok.com Internet Source	1 %
8	docobook.com Internet Source	1 %
9	Submitted to Universitas Maritim Raja Ali Haji Student Paper	1 %
10	iptek.its.ac.id Internet Source	1 %
11	eprints.uny.ac.id Internet Source	1 %
12	media.neliti.com Internet Source	1 %
13	journal.unnes.ac.id Internet Source	<1 %
14	ejournal.polbeng.ac.id Internet Source	<1 %
15	Submitted to Universitas Brawijaya Student Paper	<1 %
16	eprints.uty.ac.id Internet Source	<1 %
17	id.123dok.com Internet Source	<1 %

18

Aniq Noviciatie Ulfah, M Khairul Anam, Novi Yona Sidratul Munti, Saleh Yaakub, Muhammad Bambang Firdaus. "Sentiment Analysis of the Convict Assimilation Program on Handling Covid-19", JUITA : Jurnal Informatika, 2022

Publication

<1 %

19

Muhammad Irfan Saputra, Irwan Budiman, Dwi Kartini, Dodon Turianto Nugrahadi, Mohammad Reza Faisal. "Performance Comparison of Adaptive Neuro Fuzzy Inference System and Support Vector Machine Algorithm in Balanced and Unbalanced Multiclass Data Classification", 2021 4th International Conference of Computer and Informatics Engineering (IC2IE), 2021

Publication

<1 %

20

a-research.upi.edu

Internet Source

<1 %

21

www.e-prosiding.umnaw.ac.id

Internet Source

<1 %

22

ojs.unud.ac.id

Internet Source

<1 %

23

repository.ittelkom-pwt.ac.id

Internet Source

<1 %

www.penjualan.web.id

24

Internet Source

<1 %

25

Agus Fajar Riany, Gusmelia Testiana.
"Penerapan Data Mining untuk Klasifikasi
Penyakit Stroke Menggunakan Algoritma
Naïve Bayes", Jurnal SAINTEKOM, 2023

Publication

<1 %

26

www.scilit.net

Internet Source

<1 %

27

Johannes T.N. Krebs. "Nonparametric density
estimation for spatial data with wavelets",
Journal of Multivariate Analysis, 2018

Publication

<1 %

28

repository.unair.ac.id

Internet Source

<1 %

29

Andin Aprila Sari, Annisa Sugi Pramesty, Asma
Zulfiah Malik, Dini Nurul Haq Al-Hidayah et al.
"The Influence of Transformational Education
Prediction on Softskills of Madrasa Student
using Data Mining", Khazanah Journal of
Religion and Technology, 2023

Publication

<1 %

30

Nursyifa Azizah, Mohammad Reza Faisal,
Friska Abadi, Irwan Budiman et al. "A Vital
Sign Monitoring System Exploiting BT/BLE on
Low-cost Commercial Smartwatch for Home
Care Patients", 2023 International Seminar on

<1 %

Intelligent Technology and Its Applications (ISITIA), 2023

Publication

31 ejournal.uin-suska.ac.id <1 %
Internet Source

32 jurnal.fmipa.unmul.ac.id <1 %
Internet Source

33 tel.archives-ouvertes.fr <1 %
Internet Source

34 "Methods and Applications for Modeling and
Simulation of Complex Systems", Springer
Science and Business Media LLC, 2024 <1 %
Publication

35 journal.upgris.ac.id <1 %
Internet Source

Exclude quotes On

Exclude matches Off

Exclude bibliography On