Klasterisasi Kerusakan Bearing Motor Induksi 3 Fasa Menggunakan Metode Transformasi Wavelet Diskrit dan K-Medoids

Eska Rizqi Naufal^{1*)}, Gigih Priyandoko²⁾, and Fachrudin Hunaini³⁾

^{1, 2, 3)} Department of Electrical Engineering, Widyagama Malang University, Indonesia
Corresponding Email: ^{*)}eskanaufal1@gmail.com

Abstract – The 3 phase induction motor is a reliable and strong motor also has cheap price. However induction motor are also vulnerable, from the result of survey conducted by Electric Power Research Institute (EPRI), there are 41% cases of damage occur in the bearing caused by working environment condition, bearing age, and several other factors. Bearing fault is not easily to identified, with applying the data extraction method using the Discrete Wavelet Transform (DWT) and the K-Medoids clustering method will facilitate the identification process. The extraction method will pass the data in the form of current signals into the digital filter (Low Pass Filter and High Pass Filter) to be mapped into the region of frequency and time simultaneously, and clustering method will group data based on certain characteristics. Based on the clustering tests that have been done on the 3 phase induction motor current signal data with 3 bearing conditions, the Discrete Wavelet Transformation with mother wavelet bior1.1 decomposition level 2 and K-Medoids produce an accuracy rate of 86.8%.

Key words: Induction Motor, Bearing Fault, Discrete Wavelet Transformation, K-Medoids

I. PENDAHULUAN

Di bidang industri saat ini, motor induksi 3 fasa menjadi motor penggerak yang paling banyak digunakan, hal ini disebabkan oleh beberapa kelebihan yaitu handal, mudah dalam pengaplikasian serta memiliki harga relatif lebih murah [1]. Namun, motor ini tidak terlepas dari berbagai macam kerusakan yang disebabkan oleh beberapa faktor yaitu diantaranya umur bearing, lingkungan kerja, instalasi dan lain sebagainya [2]. Electric Power Research Institute (EPRI) melakukan survey terhadap kasus kerusakan motor induksi, bahwa 41% dari 6312 kasus kerusakan terdapat pada bagian bearing motor induksi [3]-[4]. Deteksi kerusakan bearing pada motor induksi 3 fasa harus dilakukan sejak dini, untuk menghindari *Shutdown* dari sistem motor induksi 3 fasa dan kerusakan yang lebih parah.

Penelitian terdahulu telah dilakukan oleh Purnamasari yaitu tentang monitoring kondisi *Ball Bearing* pada Motor Induksi menggunakan metode Wavelet [5]. Purnamasari melakukan ekstraksi data arus dari 4 jenis kondisi bearing pada motor induksi, kemudian mencari energi rata-rata dari data arus kondisi bearing normal, dan dilakukan perbandingan dengan energi rata-rata data arus motor kondisi *bearing* abnormal. Tingkat akurasi tertinggi pada

pengujian yang telah dilakukan yaitu sebesar 96 %. Namun metode ini hanya dapat membedakan jenis motor normal dengan motor rusak sehingga kurang efektif untuk melakukan analisis perbedaan antara kondisi kerusakan jenis bearing satu dengan lainnya.

Diagnosis kerusakan bearing juga dilakukan oleh Rianto, dengan memanfaatkan metode ekstraksi fitur *Empirical Mode Decomposition* (EMD) pada data sinyal vibrasi dan metode klasifikasi data *Artificial Neural Network* didapatkan tingkat akurasi sebesar 91% [6]. Penelitian lain juga dilakukan oleh Iradratu, dengan melakukan pengujian deteksi kerusakan bearing menggunakan metode pengolahan sinyal Fast Fourier Transform sebagai ekstraksi data dan melakukan analisis pengelompokan data menggunakan metode statistika data manual. Dari penelitian ini didapatkan hasil akurasi tertinggi yaitu sebesar 37,04% [7].

Dari penelitian yang dilakukan oleh Purnamasari dengan metode Wavelet untuk mendeteksi kerusakan bearing pada motor induksi dengan hasil akurasi sebesar 96% [5], dan pada penelitian yang dilakukan oleh Victor Asanza, tentang klasterisasi sinyal EEG untuk deteksi kinerja motorik dan imajiner motorik pada tangan dan kaki menggunakan K-Medoids didapatkan hasil tingkat akurasi 88% [8], lebih unggul dibanding dengan metode *K-Means*, *Hierarchical Clustering*, *Spectral Clustering* dan *DBSCAN Clustering* menjadi pertimbangan dalam menentukan metode Transformasi Wavelet Diskrit dan metode K-Medoids pada penelitian ini.

Wavelet merupakan metode ekstraksi fitur pada sinyal dimana sinyal asal dipecah menjadi beberapa bagian dengan frekuensi yang berbeda [9]. Metode ini dibagi menjadi 2 jenis yaitu Transformasi Wavelet Kontinu dengan prinsip kerja yaitu melakukan penjumlahan seluruh spektrum dan dikalikan dengan mother wavelet yang sudah terkompresi dan dilakukan translasi [10], yang kedua adalah Transformasi Wavelet Diskrit (DWT) dengan prinsip dasar yaitu menganalisis sinyal menggunakan teknik digital filter seperti Low Pass Filter dan High Pass Filter [11]-[12]. Secara umum CWT handal dalam menganalisis suatu sinyal data dengan frekuensi tinggi sedangkan DWT lebih handal dalam melakukan analisis pada sinyal diskrit dengan frekuensi rendah. Metode K-Medoids merupakan metode machine learning untuk *Clustering* data dengan prinsip kerja yaitu, melakukan klasterisasi atau pengelompokan data berdasarkan perbedaan karakteristik data [13]. Algoritma ini menggunakan objek data random yang akan

dikelompokkan untuk mewakili sebuah *Cluster* [14]-[15]. Beberapa kelebihan yang dimiliki oleh metode ini yaitu, mampu melakukan pengolahan data besar dengan perhitungan yang lebih cepat dan mampu mengatasi kelemahan dari metode *K-Means* yang sensitif terhadap data Outliers [16]-[17].

Dengan menggabungkan Transformasi *Wavelet Diskrit* sebagai metode ekstraksi fitur sinyal dan *K-Medoids* untuk melakukan klasterisasi data arus motor induksi 3 fasa dari beberapa jenis kerusakan *bearing* motor diharapkan mampu mendapatkan tingkat akurasi 50% atau lebih tinggi dari penelitian sebelumnya.

II. METODOLOGI

Gambar 1. Blok diagram tahapan penelitian

A. Pengambilan Data

Tahap pengambilan data dilakukan dengan memasang sensor arus pada motor induksi 3 fasa yang diberi sumber tegangan Wye 3 fasa 380 V – 400 V frekuensi 50 Hz dengan kecepatan 1400 rpm dan torsi sebesar 1.1 KW (1.5 HP). Sensor arus yang terpasang akan mengirim sinyal ke arduino dan kemudian diteruskan ke komputer atau pc melalui komunikasi serial. Data pada pengujian ini dibedakan menjadi 300 data kondisi bearing normal, 300 data kondisi *bearing* rusak *ball bearing*, dan 300 data kondisi rusak *inner race* dengan jumlah keseluruhan yaitu 900 data dan keterangan sebagai berikut,

- Bearing Normal*
Merupakan motor induksi 3 fasa dengan kondisi bearing normal.
- Bearing dengan kerusakan ball bearing*
Merupakan motor induksi 3 fasa dengan kondisi *bearing* yang telah dilas pada bagian *ball bearing*.
- Bearing dengan kerusakan inner race*

Merupakan motor induksi 3 fasa dengan kondisi *bearing* yang telah digores pada bagian cincin *bearing*.

Gambar 2. Rangkaian alat pengambilan data

B. Ekstraksi data menggunakan Transformasi Wavelet Diskrit

Transformasi Wavelet Diskrit sering digunakan dalam ekstraksi fitur pada suatu sinyal dengan mengubah sinyal ke dalam kawasan frekuensi atau domain lain. Metode ini lebih unggul dari metode *Fast Fourier Transform* (FFT) karena mampu memetakan sinyal ke dalam kawasan frekuensi dan waktu secara bersamaan untuk meminimalisir data hilang [18].

Prinsip kerja dari Transformasi Wavelet Diskrit adalah sinyal dilewatkan pada rangkaian filter digital yaitu *High Pass Filter* dan *Low Pass Filter*, kemudian setengah hasil dari keluaran diambil sebagai sampel, proses ini dinamakan dekomposisi [19]. Proses dekomposisi dapat dilakukan dengan satu atau lebih tingkatan. Blok diagram ditampilkan pada Gambar 3.

Gambar 3. Blok diagram Transformasi Wavelet Diskrit

Dimana $x[n]$ adalah data/sinyal awal, $g[n]$ adalah Low Pass Filter dan $h[n]$ *High Pass Filter*. Seluruh data dilakukan ekstraksi sebanyak 15 kali dengan menggunakan 3 jenis *mother wavelet biorthogonal* seperti pada Gambar 4.

Gambar 4. Tahap Ekstraksi Data

a. Ekstraksi dengan bior1.1

Pada pengujian pertama, seluruh data dilakukan ekstraksi sebanyak 5 kali menggunakan *mother wavelet biorthogonal* (bior1.1) dengan 5 tingkat dekomposisi berbeda pada setiap pengujian.

b. Ekstraksi dengan bior 1.5

Pada pengujian kedua, seluruh data dilakukan ekstraksi sebanyak 5 kali menggunakan *mother wavelet biorthogonal* (bior 1.5) dengan 5 tingkat dekomposisi berbeda pada setiap pengujian.

c. Ekstraksi dengan bior 2.2

Pada pengujian terakhir, seluruh data dilakukan ekstraksi sebanyak 5 kali menggunakan *mother wavelet biorthogonal* (bior 2.2) dengan 5 tingkat dekomposisi berbeda pada setiap pengujian.

C. Klasterisasi data menggunakan metode K-Medoids

K-Medoids adalah teknik klasterisasi data yang masuk dalam kelompok *unsupervised machine learning*. Metode ini melakukan pengelompokan data berdasarkan ciri atau karakteristiknya [15]. Algoritma yang digunakan berusaha meminimalisir jumlah perbedaan jarak antara masing-masing objek dengan medoid sehingga tingkat akurasi yang didapatkan lebih tinggi [20]. Berikut urutan langkah kerja dari K-Medoids [16],

1. Menentukan jumlah Cluster.
2. Menentukan titik medoid awal dari data acak dalam dataset.
3. Menghitung total jarak antara data dengan medoid terdekat menggunakan *Euclidean Distance*.
4. Menentukan titik medoid baru dari data acak dalam dataset yang belum pernah dijadikan medoid.
5. Menghitung total jarak antara data dengan medoid terdekat menggunakan *Euclidean Distance*.
6. Menghitung nilai simpangan data dengan mengurangi total jarak pada medoid baru dan medoid awal.
7. Jika nilai simpangan positif maka iterasi dihentikan, namun jika nilai simpangan negatif maka kembali ke langkah 2-7 sampai hasil nilai simpangan positif.

Pada tahap ini, keseluruhan data hasil ekstraksi diambil nilai median sebagai sumbu x dan mean sebagai sumbu y untuk dijadikan titik koordinat data. Data dimasukkan ke dalam dataset dengan urutan dari yang pertama yaitu, data bearing normal, data bearing rusak ball bearing dan yang terakhir data rusak inner race. Dataset dilakukan klasterisasi menggunakan metode machine learning K-Medoids sebanyak 15 kali dengan pembagian seperti berikut:

a. Pengujian Klasterisasi Pertama

Pada pengujian pertama, seluruh data yang telah dilakukan ekstraksi sebanyak 5 kali menggunakan *mother wavelet biorthogonal* (bior1.1) dengan 5 tingkat dekomposisi berbeda pada setiap pengujian, dilakukan klasterisasi dengan metode K-Medoids.

b. Pengujian Klasterisasi Kedua

Pada pengujian kedua, seluruh data yang telah dilakukan ekstraksi sebanyak 5 kali menggunakan *mother wavelet biorthogonal* (bior1.5) dengan 5 tingkat dekomposisi berbeda pada setiap pengujian, dilakukan klasterisasi dengan metode K-Medoids.

c. Pengujian Klasterisasi Ketiga

Pada pengujian terakhir, seluruh data yang telah dilakukan ekstraksi sebanyak 5 kali menggunakan *mother wavelet biorthogonal* (bior2.2) dengan 5 tingkat dekomposisi berbeda pada setiap pengujian, dilakukan klasterisasi dengan metode K-Medoids

D. Perancangan GUI

Tahap terakhir dari penelitian ini adalah perancangan GUI (*Graphical User interface*) pada software Matlab yang bertujuan untuk menampilkan hasil klasterisasi dan analisis data berupa grafik 2 dimensi dan parameter yang mudah dipahami. Pada tahap ini dirancang sebuah antarmuka untuk melakukan identifikasi data bearing, dimana titik cluster dari hasil klasterisasi yang telah dilakukan dan data bearing dikelompokkan atau dilakukan klasterisasi lagi menggunakan metode K-Medoids, untuk melakukan identifikasi data bearing yang akan dilakukan identifikasi.

III. HASIL DAN PEMBAHASAN

Dari pengambilan data yang telah dilakukan didapatkan data dengan 3 kondisi bearing yaitu motor dengan kondisi bearing normal, motor dengan kondisi bearing rusak ball bearing dan motor dengan kondisi bearing rusak *inner race*. Setiap kondisi bearing diambil 300 data dengan jumlah keseluruhan 900 data. Berikut beberapa hasil dari masing-masing kondisi *bearing*.

Gambar 5. Sinyal Normal

Data sinyal normal memiliki karakteristik dimana rata-rata nilai minimum -2,690 A, maksimum 3,470 A, median 0,025 A dan nilai mean 0,003 A.

Gambar 6. Sinyal rusak ball bearing

Data sinyal bearing dengan kerusakan *ball bearing* memiliki karakteristik dimana rata-rata nilai minimum -2,050, maksimum 2,730 A, median -0,100 A dan nilai mean -0,052 A.

Gambar 7. Sinyal rusak inner race

Data sinyal bearing dengan kerusakan inner race memiliki karakteristik dimana rata-rata nilai minimum -3,170 A, maksimum 1,810 A, median -0,075 dan nilai mean -0,060 A.

Tahap selanjutnya adalah ekstraksi data, dimana pada tahap ekstraksi data dilakukan menggunakan metode Transformasi Wavelet Diskrit dengan 3 jenis *mother wavelet biorthogonal* (bior1.1, bior1.5 dan bior2.2). Hasil keseluruhan ekstraksi dianalisis untuk mendapatkan nilai median dan mean data.

a. Ekstraksi data bior1.1

Pengujian tahap pertama ekstraksi data dilakukan menggunakan metode Transformasi Wavelet Diskrit dengan *mother wavelet* bior1.1. Hasil dari setiap pengujian ekstraksi tahap pertama dilakukan pencarian nilai median dan mean untuk selanjutnya disimpan dan dijadikan sebagai representasi maupun titik koordinat data. Pada **Tabel 1** dan **Tabel 2** ditampilkan range nilai median dan mean data hasil pengujian ekstraksi menggunakan metode Transformasi Wavelet Diskrit dengan *mother wavelet biorthogonal* bior1.1.

Tabel 1. Range nilai median data

Nilai	Tingkat Dekomposisi				
	1	2	3	4	5
Maksimum Bearing Normal	0,106	0,001	0,050	-0,020	-0,047
Minimum Bearing Normal	0,004	-0,035	0,001	-0,033	-0,122
Maksimum Bearing Rusak Ball Bearing	0,064	0,060	0,084	0,105	0,149
Minimum Bearing Rusak Ball Bearing	0,042	-0,068	-0,113	-0,071	-0,186
Maksimum Bearing Rusak Inner Race	-0,028	-0,123	-0,163	-0,219	-0,309
Minimum Bearing Rusak Inner Race	-0,085	-0,140	-0,198	-0,353	-0,499

Tabel 2. Range nilai mean data

Nilai	Tingkat Dekomposisi				
	1	2	3	4	5
Maksimum Bearing Normal	0,000	0,010	0,015	0,080	0,113
Minimum Bearing Normal	-0,002	-0,010	-0,018	-0,084	-0,203
Maksimum Bearing Rusak Ball Bearing	-0,099	-0,083	-0,138	-0,259	-0,412
Minimum Bearing Rusak Ball Bearing	-0,120	-0,168	-0,237	-0,326	-0,461
Maksimum Bearing Rusak Inner Race	0,764	-0,104	-0,147	-0,108	-0,152
Minimum Bearing Rusak Inner Race	-0,094	-0,158	-0,226	-0,331	-0,295

Dari Tabel range nilai median dan mean pengujian ekstraksi bior1.1 terlihat bahwa pada range nilai mean level dekomposisi 2 dan 3 memiliki perbedaan lebih baik antara bearing normal dan *bearing rusak ball bearing* maupun rusak *inner race*. Hal ini disebabkan karena range data normal tidak tertindih oleh data bearing rusak ball bearing maupun rusak inner race, sehingga persebaran data terdapat sedikit perbedaan antara ketiga kondisi bearing dan mempermudah K-Medoids untuk melakukan pengelompokan.

b. Ekstraksi data bior1.5

Pengujian tahap kedua ekstraksi data dilakukan menggunakan metode Transformasi Wavelet Diskrit dengan *mother wavelet* bior1.5. Hasil dari setiap pengujian ekstraksi tahap pertama dilakukan pencarian nilai median dan mean untuk selanjutnya disimpan dan dijadikan sebagai representasi maupun titik koordinat data. Pada **Tabel 3** dan **Tabel 4** ditampilkan range nilai median dan mean data hasil pengujian ekstraksi

menggunakan metode Transformasi Wavelet Diskrit dengan mother wavelet biorthogonal bior1.5.

Tabel 3. Range nilai median data

Nilai	Tingkat Dekomposisi				
	1	2	3	4	5
Maksimum Bearing Normal	0,179	0,088	0,234	0,528	0,993
Minimum Bearing Normal	0,031	-0,004	0,051	0,172	0,244
Maksimum Bearing Rusak Ball Bearing	0,052	0,085	0,153	0,270	0,418
Minimum Bearing Rusak Ball Bearing	0,039	-0,041	0,037	0,092	0,186
Maksimum Bearing Rusak Inner Race	-0,001	-0,130	-0,177	-0,337	-0,555
Minimum Bearing Rusak Inner Race	-0,087	-0,135	-0,212	-0,372	-0,558

Tabel 4. Range nilai mean data

Nilai	Tingkat Dekomposisi				
	1	2	3	4	5
Maksimum Bearing Normal	0,000	0,017	0,067	0,222	0,347
Minimum Bearing Normal	-0,009	0,016	0,049	0,119	0,239
Maksimum Bearing Rusak Ball Bearing	-0,117	-0,097	-0,131	-0,255	-0,375
Minimum Bearing Rusak Ball Bearing	-0,124	-0,160	-0,209	-0,277	-0,393
Maksimum Bearing Rusak Inner Race	0,583	-0,121	-0,129	-0,122	-0,149
Minimum Bearing Rusak Inner Race	-0,096	-0,153	-0,145	-0,156	-0,179

Dari Tabel range nilai median dan mean pengujian ekstraksi bior1.5 terlihat bahwa pada range nilai mean level dekomposisi 2 dan 3 memiliki perbedaan lebih baik antara bearing normal dan bearing rusak ball bearing maupun rusak inner race. Hal ini disebabkan karena range data normal tidak tertindih oleh data bearing rusak ball bearing maupun rusak inner race, sehingga persebaran data terdapat sedikit perbedaan antara ketiga kondisi bearing dan mempermudah K-Medoids untuk melakukan pengelompokan.

c. Ekstraksi data bior2.2

Pengujian tahap ketiga ekstraksi data dilakukan menggunakan metode Transformasi Wavelet Diskrit dengan mother wavelet bior2.2. Hasil dari setiap pengujian ekstraksi tahap pertama dilakukan pencarian nilai median dan mean untuk selanjutnya disimpan dan dijadikan sebagai representasi maupun titik koordinat data. Pada **Tabel 5** dan **Tabel 6** ditampilkan range nilai

median dan mean data hasil pengujian ekstraksi menggunakan metode Transformasi Wavelet Diskrit dengan mother wavelet biorthogonal bior2.2.

Tabel 5. Range nilai median data

Nilai	Tingkat Dekomposisi				
	1	2	3	4	5
Maksimum Bearing Normal	-0,012	-0,001	-0,046	-0,015	0,071
Minimum Bearing Normal	-0,053	-0,025	-0,047	-0,177	-0,087
Maksimum Bearing Rusak Ball Bearing	0,021	0,022	-0,050	0,170	-0,023
Minimum Bearing Rusak Ball Bearing	-0,143	-0,058	-0,118	-0,125	-0,326
Maksimum Bearing Rusak Inner Race	-0,078	-0,108	-0,146	-0,230	-0,244
Minimum Bearing Rusak Inner Race	-0,347	-0,134	-0,211	-0,235	-0,385

Tabel 6. Range nilai mean data

Nilai	Tingkat Dekomposisi				
	1	2	3	4	5
Maksimum Bearing Normal	0,064	0,105	0,330	0,749	1,545
Minimum Bearing Normal	0,034	-0,041	0,056	0,133	1,530
Maksimum Bearing Rusak Ball Bearing	0,099	-0,123	-0,094	-0,035	0,105
Minimum Bearing Rusak Ball Bearing	-0,102	-0,125	-0,135	-0,241	-0,232
Maksimum Bearing Rusak Inner Race	1,151	-0,065	0,042	0,351	0,870
Minimum Bearing Rusak Inner Race	-0,075	-0,154	-0,250	-0,130	0,328

Dari Tabel range nilai median dan mean pengujian ekstraksi bior1.5 terlihat bahwa pada range nilai mean level dekomposisi 2 dan range nilai median level dekomposisi 3 memiliki perbedaan lebih baik antara bearing normal dan bearing rusak ball bearing maupun rusak inner race. Hal ini disebabkan karena range data normal tidak tertindih oleh data bearing rusak ball bearing maupun rusak inner race, sehingga persebaran data terdapat sedikit perbedaan antara ketiga kondisi bearing dan mempermudah K-Medoids untuk melakukan pengelompokan.

Hasil dari keseluruhan pengujian ekstraksi data dapat disimpulkan bahwa, range nilai median dan mean data bearing normal memiliki nilai signifikan lebih kecil dari data bearing dengan kerusakan ball bearing maupun inner race, hal ini disebabkan karena bearing dengan kondisi rusak membutuhkan arus yang lebih besar untuk memberi daya lebih ke rotor agar berputar. Setelah data hasil ekstraksi disimpan tahap selanjutnya adalah, nilai mean dan median dijadikan sebagai titik

koordinat data dan dimasukkan pada dataset dengan urutan mulai data dari bearing normal, bearing rusak ball bearing dan bearing rusak inner race. Dataset dilakukan pengujian klasterisasi atau pengelompokan data menggunakan metode K-Medoids sebanyak 15 kali yang dibagi menjadi 3 tahap.

Tabel 7. Hasil Klasterisasi Tahap Pertama

Jumlah Anggota	Tingkat Dekomposisi				
	1	2	3	4	5
Cluster 1	27	278	211	245	172
Cluster 2	295	229	269	168	243
Cluster 3	32,1	274	282	228	208

Pada tahap pertama pengujian klasterisasi dilakukan dengan menggabungkan metode ekstraksi Transformasi Wavelet Diskrit bior1.1 dengan 5 tingkat dekomposisi dan metode klasterisasi K-Medoids hasil klasterisasi ditampilkan pada **Tabel 7**.

Tabel 8. Hasil Klasterisasi Tahap Kedua

Jumlah Anggota	Tingkat Dekomposisi				
	1	2	3	4	5
Cluster 1	34	251	241	236	138
Cluster 2	26	223	148	186	231
Cluster 3	296	272	241	118	125

Tahap kedua pengujian klasterisasi dilakukan dengan menggabungkan metode ekstraksi Transformasi Wavelet Diskrit bior1.5 dengan 5 tingkat dekomposisi dan metode klasterisasi K-Medoids hasil klasterisasi ditampilkan pada **Tabel 8**.

Tabel 9. Hasil Klasterisasi Tahap Ketiga

Jumlah Anggota	Tingkat Dekomposisi				
	1	2	3	4	5
Cluster 1	39	249	249	108	96
Cluster 2	21	156	114	243	255
Cluster 3	294	183	138	111	93

Tahap terakhir pengujian klasterisasi dilakukan dengan menggabungkan metode ekstraksi Transformasi Wavelet Diskrit bior2.2 dengan 5 tingkat dekomposisi dan metode klasterisasi K-Medoids hasil klasterisasi ditampilkan pada tabel 9. Setelah didapatkan hasil klasterisasi maka dilakukan analisis tingkat akurasi dengan membandingkan input data dan hasil output klasterisasi.

Tabel 10. Hasil Klasterisasi menggunakan DWT bior1.1

Tingkat Akurasi	Tingkat Dekomposisi				
	1	2	3	4	5
Cluster 1	9%	92,7%	70,3%	81,7%	57,3%
Cluster 2	98,3%	76,3%	89,7%	56%	81%
Cluster 3	10,7%	91,3%	94,%	76%	69,3%
Seluruh Cluster	39,3%	86,8%	84,7%	71,2%	69,2%

Dari **Tabel 10** dapat disimpulkan bahwa pada tingkat akurasi tertinggi Cluster 1 yaitu sebesar 92,7% pada tingkat dekomposisi 2, Cluster 2 sebesar 98,3% pada tingkat dekomposisi 1, Cluster 3 sebesar 91,3% pada tingkat dekomposisi 2 dan tingkat akurasi seluruh Cluster terdapat pada tingkat dekomposisi 2 sebesar 86,2%.

Tabel 11. Hasil Klasterisasi menggunakan DWT bior1.5

Tingkat Akurasi	Tingkat Dekomposisi				
	1	2	3	4	5
Cluster 1	11,3%	83,7%	80,3%	78,7%	46%
Cluster 2	8,7%	74,3%	49,3%	62%	77%
Cluster 3	98,7%	90,7%	80,3%	39,3%	41,7%
Seluruh Cluster	39,6%	82,9%	70%	60%	54,9%

Dari **Tabel 11** dapat disimpulkan bahwa pada tingkat akurasi tertinggi Cluster 1 yaitu sebesar 83,7% pada tingkat dekomposisi 2, Cluster 2 sebesar 74,3% pada tingkat dekomposisi 2, Cluster 3 sebesar 98,7% pada tingkat dekomposisi 1 dan tingkat akurasi seluruh Cluster terdapat pada tingkat dekomposisi 2 sebesar 82,9%.

Tabel 12. Hasil Klasterisasi menggunakan DWT bior2.2

Tingkat Akurasi	Tingkat Dekomposisi				
	1	2	3	4	5
Cluster 1	13%	83%	83%	36%	32%
Cluster 2	7%	52%	38%	81%	85%
Cluster 3	98%	61%	46%	37%	31%
Seluruh Cluster	39%	65%	56%	51%	49%

Dari **Tabel 12** dapat disimpulkan bahwa pada tingkat akurasi tertinggi Cluster 1 yaitu sebesar 83% pada tingkat dekomposisi 2 dan 3, Cluster 2 sebesar 85% pada tingkat dekomposisi 5, Cluster 3 sebesar 98% pada tingkat dekomposisi 1 dan tingkat akurasi seluruh Cluster terdapat pada tingkat dekomposisi 2 sebesar 65%.

Gambar 8. Klasterisasi data dekomposisi DWT tingkat 2

Hasil dari ketiga tahap klasterisasi didapatkan tingkat akurasi klasterisasi terbaik yaitu pada *mother wavelet biorthogonal* tingkat dekomposisi 2 sebesar 86,8%. Berikut klasterisasi data hasil ekstraksi Transformasi Wavelet Diskrit *biorthogonal* (bior1.1) dengan tingkat dekomposisi 2 ditampilkan dalam bentuk grafik 2 dimensi pada Gambar 8.

Untuk mempermudah proses klasterisasi data dan identifikasi data maka dirancang sebuah antarmuka atau jendela GUI pada software Matlab.

Gambar 9. Jendela Identifikasi Data

Gambar 9. merupakan antarmuka untuk melakukan identifikasi data *bearing* berdasarkan hasil klasterisasi yang telah dilakukan. Terdapat 3 buah *push button* yaitu untuk memilih titik K-Medoids yang telah didapatkan dari hasil klasterisasi sebelumnya, kemudian *push button* Data Bearing untuk pemilihan data *bearing* yang akan diidentifikasi dan *push button* Mulai untuk memulai proses identifikasi data. Pada jendela ini ditampilkan beberapa informasi yaitu titik K-Medoids dari 3 jenis

kondisi bearing, jenis Transformasi Wavelet Diskrit yang digunakan beserta tingkat dekomposisi, titik koordinat data bearing yang akan diidentifikasi, grafik dua dimensi titik koordinat bearing, dan hasil identifikasi jenis bearing.

IV. KESIMPULAN

Dari hasil penelitian Klasterisasi kerusakan *bearing* menggunakan Transformasi Wavelet Diskrit dan K-Medoids didapatkan beberapa kesimpulan yaitu, Dari keseluruhan pengujian ekstraksi data, range nilai median dan mean data bearing normal memiliki nilai signifikan lebih kecil dari data *bearing* dengan kerusakan *ball bearing* maupun *inner race*, hal ini disebabkan karena bearing dengan kondisi rusak membutuhkan arus yang lebih besar untuk memaksa rotor. Pengujian klasterisasi dengan K-Medoids yang dilakukan sebanyak 15 kali didapatkan kesimpulan bahwa masing-masing hasil ekstraksi data Transformasi Wavelet Diskrit *Biorthogonal* (bior1.1, bior1.5 dan bior2.2) dengan tingkat dekomposisi 2 memiliki nilai akurasi tertinggi yaitu, pada bior1.1 sebesar 86,8%, bior1.5 sebesar 82,9% dan bior2.2 sebesar 65%. Klasterisasi data menggunakan K-Medoids dengan Transformasi Wavelet Diskrit jenis *mother wavelet biorthogonal* (bior1.1) tingkat dekomposisi 2, merupakan hasil dengan tingkat akurasi klasterisasi tertinggi yaitu sebesar 86,8 % lebih tinggi daripada metode monitoring kerusakan bearing yang dilakukan oleh Purnamasari dengan hanya menggunakan Transformasi Wavelet.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada Dosen pembimbing Jurusan Teknik Elektro Universitas Widyagama yang telah membimbing keberlangsungan penulisan artikel ini.

DAFTAR PUSTAKA

- [1] J. S. Sufrianti and A. H. Hamzah, "Simulasi Dan Deteksi Gangguan Belitan Stator Motor Induksi Tiga Fasa Menggunakan Arus Starting Dengan Matlab/Simulink," *Jom FTEKNIK*, vol. 4, pp. 1–11, 2017.
- [2] D. Meidiasha, M. Rif, and M. Subekti, "Alat Pengukur Getaran, Suara Dan Suhu Motor Induksi Tiga Fasa Sebagai Indikasi Kerusakan Motor Induksi Berbasis Arduino," *J. Electr. Vocat. Educ. Technol.*, vol. 5, no. 1, pp. 366–370, 2020.
- [3] M. Abduh, I. D.P.K, and B. Y. Dewantara, "Deteksi Kerusakan Outer Race Bearing pada Motor Induksi Menggunakan Analisis Arus Stator," *Semin. Nas. Inov. dan Apl. Teknol. di Ind.*, vol. 1, no. 2, pp. 1–6, 2019.
- [4] A. Radiansyah and A. Gifson, "Inspeksi Overhaul Motor Induksi 3 Fasa 1000 KW di PT. Mesindo Teknnesia," *TESLA J. Tek. Elektro*, vol. 21, no. 2, pp. 14–26, 2019.
- [5] E. R. Purnamasari, I. Diah, and B. Y. Dewantara, "Monitoring Kondisi Ball Bearing Pada Motor Induksi Melalui Analisa Arus Stator Berbasis Wavelet Transform," *Pros. SNST ke-10 Tahun 2019 Fak. Tek.*

- Univ. Wahid Hasyim 49, pp. 48–53, 2019.
- [6] B. P. W. Rianto, E. S. Ningrum, Z. Darojah, and H. Hermawan, “Artificial Neural Network Through Energy Value of Empirical Mode Decomposition Feature Extraction based: Application on Bearing Fault Diagnosis,” *IES 2019 - Int. Electron. Symp. Role Techno-Intelligence Creat. an Open Energy Syst. Towar. Energy Democr. Proc.*, pp. 387–393, 2019.
- [7] Iradiratu, “Deteksi Kerusakan Inner Race Bearing Menggunakan Motor Current Signature Analysis Berbasis Fast Fourier Transform,” *J. Tek. Elektro Dan Komput. Triac*, vol. 6, no. 1, pp. 6–9, 2019.
- [8] V. Asanza, E. Pelaez, and F. Loayza, “EEG signal clustering for motor and imaginary motor tasks on hands and feet,” *2017 IEEE 2nd Ecuador Tech. Chapters Meet.*, vol. 2017-Jan, pp. 1–5, 2018.
- [9] F. Ilman Huda, I. D.P.K, and B. Yan Dewantara, “Identifikasi Gangguan Belitan Stator Motor Induksi Metode Wavelet,” *Pros. SNST ke-10 Tahun 2019*, pp. 42–47, 2017.
- [10] N. Hasanah, A. B. Muljono, and I. M. B. Suksmadana, “Penentuan Lokasi Gangguan Hubung Singkat Pada Saluran Transmisi 150 Kv Berbasis Transformasi Wavelet,” *Dielektrika*, vol. 5, no. 1, pp. 42–47, 2018.
- [11] V. Apryaleva, B. Hidayat, and S. Aulia, “Simulasi Dan Analisis Sistem Klasifikasi Batubara Menggunakan Discrete Wavelet Transform (Dwt), Fuzzy Color Histogram (Fch) Dan K-Nearest Neighbor (K-Nn) Pada Citra Digital,” *e-Proceeding Eng.*, vol. 3, no. 2, pp. 1911–1918, 2016.
- [12] T. I. Saputra, F. Fauziah, and N. Hayati, “Implementasi Discrete Wavelet Transform Pada Aplikasi Kompresi Citra Medis,” *J. InfomediaTeknik Inform. Multimed. Jar.*, vol. 4, no. 2, pp. 101–107, 2020.
- [13] I. Kamila, U. Khairunnisa, and Mustakim, “Perbandingan Algoritma K-Means dan K-Medoids untuk Pengelompokan Data Transaksi Bongkar Muat di Provinsi Riau,” *J. Ilm. Rekayasa dan Manaj. Sist. Inf.*, vol. 5, no. 1, pp. 119–125, 2019.
- [14] Z. Mustofa and I. S. Suasana, “Algoritma Clustering K-Medoids pada E-Government Bidang Information and Communication,” *J. Teknol. Inf. dan Komun.*, vol. 9, no. 1, pp. 1–10, 2018.
- [15] A. Amalia, D. R., Narasatu, R., Faqih, “Perbandingan Hasil Klasifikasi Rasa Minuman Thai Tea yang Paling Digemari Menggunakan K-means dan K-medoids,” *Pros. Semin. Nas. Unimus*, vol. 2, pp. 401–407, 2019.
- [16] D. F. Pramesti, Lahan, M. Tanzil Furqon, and C. Dewi, “Implementasi Metode K-Medoids Clustering Untuk Pengelompokan Data,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 9, pp. 723–732, 2017.
- [17] M. I. Ghazali, R. Z. Ehwan, and W. H. Sugiharto, “Analisa Pola Belanja Menggunakan Algoritma Fp Growth, Self Organizing Map (Som) Dan K Medoids,” *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 8, no. 1, pp. 317–326, 2017.
- [18] M. Basis, O. Equipment, and E. Oee, “Penentuan Fungsi Basis Wavelet Terbaik Untuk Sinyal Suara,” *Simp. Nas. Teknol. Terap. 5*, vol. 3, no. 1988, pp. 172–178, 2017.
- [19] B. Robi’in, “Analisis Dekomposisi Wavelet Pada Pengenalan Pola Lurik Dengan Metode Learning Vector Quantization,” *Ilk. J. Ilm.*, vol. 9, pp. 153–160, 2017.
- [20] W. S. Manjoro, M. Dhakar, and B. K. Chaurasia, “Operational analysis of k-medoids and k-means algorithms on noisy data,” *Int. Conf. Commun. Signal Process. ICCSP 2016*, pp. 1500–1505, 2016.