

**DIAGNOSIS KERUSAKAN BANTALAN GELINDING MENGGUNAKAN
METODE *RADIAL BASIS FUNCTION NEURAL NETWORK* (RBFNN)**

Tesis
untuk memenuhi sebagian persyaratan
mencapai derajat Sarjana S-2 Program Studi
Magister Sistem Informasi



Mariza Devega
24010411400034

PROGRAM PASCASARJANA
UNIVERSITAS DIPONEGORO
SEMARANG
2013

HALAMAN PENGESAHAN

[HALAMAN SENGAJA DIKOSONGKAN]

**HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TESIS UNTUK
KEPENTINGAN AKADEMIS**

[HALAMAN INI SENGAJA DIKOSONGKAN]

HALAMAN PERNYATAAN

[HALAMAN INI SENGAJA DIKOSONGKAN]

KATA PENGANTAR

Alhamdulillah, segala puji syukur dipanjatkan kehadirat Allah SWT, atas segala rahmat dan karunia-Nya, sehingga tesis dengan judul “*Diagnosis Kerusakan Bantalan Gelinding menggunakan Metode Radial Basis Function Neural Network (RBFNN)*” ini dapat diselesaikan dengan baik. Tesis ini disusun sebagai salah satu syarat untuk mencapai derajat Sarjana S-2 pada program studi Magister Sistem Informasi Universitas Diponegoro Semarang. Pada kesempatan ini penulis ingin mengucapkan terimakasih kepada :

1. Ketua program studi Magister Sistem Informasi Bapak Drs. Bayu Surarso, M.Sc., Ph.D.
2. Bapak Ir. Toni Prahasto, M.ASc., Ph.D., selaku dosen pembimbing I yang sudah memberikan penulis kesempatan untuk bergabung dalam penelitian ini serta secara tidak langsung mengajarkan arti pentingnya kerja keras, tanggungjawab dan konsekuensi dalam segala hal.
3. Bapak Dr. Achmad Widodo, ST., MT., selaku dosen pembimbing II yang juga sudah memberikan waktu, ilmu, arahan dan bimbingan yang baik dalam melakukan penelitian ini.
4. Semua pihak yang sudah membantu demi kelancaran tesis ini yang tidak bisa disebutkan satu persatu, terimakasih atas doa dan dukungannya selama ini.

Akhir kata, penulis menyadari bahwa tesis ini masih memiliki banyak kekurangan keterbatasan, oleh karena itu penulis mengharapkan saran dan kritik yang membangun demi pengembangan kesempurnaan tesis ini.

Semarang, Mei 2013

Penulis

DAFTAR ISI

	halaman
HALAMAN JUDUL	i
HALAMAN PENGESAHAN.....	ii
HALAMAN PERNYATAAN PERSETUJUAN PUBLIKASI TESIS UNTUK KEPENTINGAN AKADEMIS	iii
HALAMAN PERNYATAAN	iv
KATA PENGANTAR	v
DAFTAR ISI.....	vi
DAFTAR GAMBAR	viii
DAFTAR TABEL.....	ix
DAFTAR ARTI LAMBANG DAN SINGKATAN	x
ABSTRAK	xi
ABSTRACT	xii
BAB I PENDAHULUAN	
1.1 Latar Belakang.....	1
1.2 Tujuan Penelitian.....	4
1.3 Manfaat Penelitian.....	4
BAB II TINJAUAN PUSTAKA DAN DASAR TEORI	
2.1 Tinjauan Pustaka	5
2.2 Dasar Teori	8
2.2.1 Bantalan Gelinding	8
2.2.2 Pemantauan Kondisi Getaran	9
2.2.3 Pengukuran Getaran	10
2.2.4 Format Presentasi Data.....	12
2.2.5 <i>Data Mining</i> Getaran.....	12
2.2.6 Data Preprocessing	13
2.2.7 Deskriptif Statistik.....	13

2.2.8	Ekstraksi Fitur	13
2.2.9	Seleksi Fitur.....	14
2.2.10	<i>Principal Component Analysis (PCA)</i>	15
2.2.11	Proses Klasifikasi	17
2.2.11.1	Radial Basis Function Neural Network (RBFNN).....	17
2.2.11.2	Fungsi Basis Radial.....	18

BAB III METODE PENELITIAN

3.1	Bahan dan Alat Penelitian	21
3.2	Prosedur Penelitian	21
3.3.1	Klasifikasi menggunakan metode RBFNN	25
3.3.2	Script Penelitian.....	27
3.3.3.1	Reduksi Fitur	27
3.3.3.2	Pelatihan	28
3.3.3.3	Pengujian	30

BAB IV HASIL DAN PEMBAHASAN

4.1	Pelaksanaan Penelitian	32
4.1.1	Skenario.....	34
4.1.2	Ekstraksi Fitur	38
4.1.4	<i>Principal Component Analysis (PCA)</i>	40
4.1.5	<i>Plot</i> Fitur	41
4.1.6	<i>Moment</i> Statistik (Niu et al, 2005)	43
4.1.6	Klasifikasi	45
4.1.7	Pelatihan dan Pengujian	47
4.2	Pembahasan	48

BAB V KESIMPULAN DAN SARAN

5.1	Kesimpulan	52
5.2	Saran	52

DAFTAR PUSTAKA

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Bantalan Gelinding (Bearings).....	9
Gambar 2.2 Pemasangan sensor getaran pada rumah bantalan dengan posisi sumbu mesin horisontal (ISO 13373)	12
Gambar 2.3 Pemasangan sensor getaran pada rumah bantalan dengan posisi sumbu mesin vertikal (ISO 13373)	12
Gambar 2.4 Arsitektur RBFNN	20
Gambar 3.1 Alur Penelitian.....	22
Gambar 3.2 <i>Flowchart</i> Sistem	25
Gambar 3.3 Flowchart RBFNN	27
Gambar 4.1 Perangkat simulator kerusakan mesin (MFS)	33
Gambar 4.2 Sinyal Getaran Kelas <i>Angular Misalignment</i>	34
Gambar 4.3 Sinyal Getaran kelas <i>Phase Unbalanced</i>	35
Gambar 4.4 Format Data.....	37
Gambar 4.5 Data latih dan data uji.....	38
Gambar 4.6 Penambahan 4 fitur.....	40
Gambar 4.7 Reduksi Fitur	41
Gambar 4.8 Plot fitur mean	42
Gambar 4.9 Plot fitur 22	44
Gambar 4.10 Hasil Simulasi 4 parameter statistik.....	45
Gambar 4.11 klasifikasi dengan data prtools	47
Gambar 4.12 Klasifikasi dengan data getaran.....	48
Gambar 4.13 Klasifikasi pengujian <i>multi class</i>	49

DAFTAR TABEL

	halaman
Tabel 4.1 Tabel Fitur Statistik.....	36
Tabel 4.2 Tabel Missclassify.....	49
Tabel 4.3 Tabel Akurasi	51
Tabel 4.4 Pengujian <i>Multi Class</i>	53

DAFTAR ARTI LAMBANG DAN SINGKATAN

DAFTAR ARTI LAMBANG

Lambang	Arti Lambang
S	<i>Skewness</i>
K	<i>Kurtosis</i>
N	Jumlah data
Exp	Exponen/bilangan euler
\mathfrak{R}	Fungsi basis radial
μ	Rata-rata
σ	Varian / standar deviasi
ϕ	Fungsi <i>Gaussian</i>
Dist(i,k)	Jarak euclidean antara vektor i dan vektor k
$\ .\ $	Norm jarak euclidean
c	Vektor center
x	<i>Input</i> vektor
y	<i>Output</i> fungsi basis radial
A	<i>Output hidden layer</i>
W	Bobot

DAFTAR SINGKATAN

Singkatan	Arti Singkatan
<i>RBNN</i>	<i>Radial Basis Function Neural Network</i>
<i>MFS</i>	<i>Machine Fault Simulator</i>
<i>Ar</i>	<i>Auto Regression</i>
<i>RMS</i>	<i>Root Means Square</i>
<i>LMS</i>	<i>Least Mean Square</i>
<i>RMSF</i>	<i>Root Means Square Ferquency</i>
<i>AMIS</i>	<i>Angular Misalignment</i>
<i>BR</i>	<i>Bowod Rotor Shaft</i>
<i>BRB</i>	<i>Broken Rotor Bar</i>
<i>FBO</i>	<i>Faulty Bearing (outrace)</i>
<i>MUN</i>	<i>Rotor Unbalanced</i>
<i>NOR</i>	<i>Normal Motor</i>
<i>PMIS</i>	<i>Parallel Misalignment</i>
<i>PUN</i>	<i>Phase Unbalance</i>

ABSTRAK

Pada penelitian ini telah dilakukan diagnosis kerusakan bantalan gelinding pada mesin industri. Penelitian ini didasarkan bahwa suatu bantalan gelinding memegang peranan penting dalam suatu mesin yang berputar. Kerusakan bantalan gelinding dapat berakibat fatal yang dapat merugikan perusahaan. Oleh karena itu diagnosis kerusakan penting dilakukan untuk mencegah terjadinya kerugian dan kerusakan pada komponen lain pada suatu mesin.

Diagnosis kerusakan dilakukan dengan mengklasifikasikan delapan jenis kerusakan. Delapan jenis kerusakan ini merupakan jenis-jenis kerusakan yang umumnya terjadi pada bantalan gelinding. Penelitian dimulai ekstraksi fitur, seleksi fitur dan proses klasifikasi. Proses klasifikasi menggunakan metode *Radial Basis Function Neural Network* (RBFNN).

Hasil menunjukkan bahwa RBFNN memiliki performa yang cukup bagus dalam mengklasifikasi. Hal ini dapat terlihat dari akurasi yang dihasilkan dari masing-masing kelas.

Kata kunci : diagnosis, bantalan gelinding, RBFNN, ekstraksi fitur

ROLLING ELEMENT BEARING FAULT DIAGNOSIS USING RADIAL BASIS FUNCTION NEURAL NETWORK (RBFNN)

ABSTRACT

Fault diagnosis of rolling element bearings on industrial machinery has been investigated in this research. This research was conducted because a rolling element bearings is one of the vital parts on the rotating machine that hold an important role. Faulty bearings make the fatal effect and company loss Therefore a fault diagnosis is important to prevent the disadvantage the damage to other components of a machines.

Fault diagnosis conducted with classifying eight types of fault. This eight types of fault are kind of fault that commonly occurred in rolling element bearings. This research starts from feature extraction, feature selection, dan classification process. The classification process is using Radial Basis Function Neural Network (RBFNN).

Results showed that the RBFNN has quite good performance in classifying. This is can be seen on the accuracy from each class.

Keywords: diagnosis, rolling element bearings, RBFNN, feature extraction

BAB I

PENDAHULUAN

1.1 Latar Belakang

Machine learning merupakan suatu bagian dalam *artificial intelligence* atau kecerdasan buatan yang berhubungan dengan pengembangan teknik-teknik yang bisa diprogramkan dan belajar dari masa lalu (Santosa, 2007). Dalam kecerdasan buatan terdapat proses pembelajaran dengan pelatihan (*supervised learning*) dan proses pembelajaran tanpa pelatihan (*unsupervised learning*). Seringkali *machine learning* ini dijadikan alat analisis dalam *data mining*.

Data Mining merupakan suatu proses menemukan hubungan yang berarti, pola, kecenderungan dengan memeriksa sekumpulan besar data yang tersimpan dalam penyimpanan dengan menggunakan teknik pengenalan pola, seperti teknik statistik dan matematika (Larose, 2005). Terdapat enam fungsi atau sub kegiatan yang ada dalam data mining dalam menemukan, menggali, atau menambang pengetahuan, yaitu: fungsi deskripsi, estimasi, prediksi, klasifikasi, pengelompokan dan fungsi asosiasi.

Fungsi yang akan dibahas lebih jauh adalah fungsi klasifikasi. Teknik Klasifikasi dan Pengenalan Pola adalah suatu alat untuk menyelesaikan masalah-masalah dalam mesin/komputer cerdas, yang digunakan pada tahap pra-pemrosesan data dan pembuat keputusan. Tujuan klasifikasi dan pengenalan pola adalah mencirikan suatu pola untuk dicari perbedaan dan kesamaannya untuk kemudian dikelompokkan berdasarkan kesamaan atau perbedaannya tersebut.

Pada proses klasifikasi, banyaknya kelas sudah ditentukan terlebih dahulu. klasifikasi juga diartikan sebagai salah satu tugas data mining yang paling umum. Klasifikasi meliputi pemeriksaan fitur baru yang disajikan dalam satu set standar kelas (Berry and Linoff, 2004).

Ada beberapa metode yang sering digunakan dalam proses klasifikasi, salah satunya adalah Jaringan saraf fungsi basis radial (*Radial Basis Function Neural Network= RBFNN*). RBFNN merupakan suatu metode jaringan saraf basis radial yang terbentuk dengan baik karena kemampuannya untuk fungsi aproksimasi dan masalah klasifikasi (Zhang et al., 2006). RBFNN memiliki kelebihan yaitu struktur jaringan yang sederhana sehingga proses pembelajarannya cepat dan juga memiliki kemampuan aproksimasi lebih baik jika dibandingkan dengan jaringan saraf tiruan (Jili and Ning, 2007).

RBFNN dapat diaplikasikan dalam berbagai domain permasalahan antara lain regresi, klasifikasi dan prediksi *time series* (Orr, 1996), sedangkan menurut (Purwitasari et al., 2011) pengaplikasiannya selain klasifikasi dan *time series* juga diaplikasikan pada pengenalan suara, restorasi gambar, estimasi gerak dan segmentasi benda bergerak.

Objek dari penelitian ini adalah bantalan gelinding pada mesin industri. Penggunaan bantalan gelinding dalam berbagai kondisi pembebanan pada banyak sistem permesinan akan mengakibatkan kerusakan pada bantalan tersebut. Modus yang dominan dalam rusaknya bantalan gelinding mesin disebabkan ketika apabila suatu bantalan gelinding itu mengalami kelelahan, kemudian menyebabkan terjadinya celah/kerusakan kecil mulai dari bawah permukaan logam kemudian menjalar menuju permukaan logam atau *spall*.

Sebuah mesin dapat menjadi sangat berbahaya jika kesalahan terjadi pada bantalan gelinding pada saat beroperasi. Deteksi dini menjadi penting untuk mencegah terjadinya kerusakan pada komponen lain sebuah mesin. Diagnosis pada bantalan gelinding dilakukan berdasarkan pemeriksaan cacat yang terjadi. Cacat pada bantalan gelinding dapat dikategorikan sebagai cacat yang terlokalisir dan cacat yang terdistribusi. Cacat yang terlokalisir meliputi retak, lubang dan serpihan yang mana disebabkan oleh kelelahan pada permukaan putaran. Kategori lain adalah cacat yang

terdistribusi, meliputi kekasaran permukaan, gelombang pada permukaan dan lintasan yang sudah tidak benar serta elemen putar yang sudah aus.

Kerusakan pada bantalan gelinding dapat berakibat fatal dan mengakibatkan biaya penghentian yang mahal. Oleh karena itu proses pemantauan bantalan gelinding penting untuk pemeliharaan mesin dan proses otomasi. Proses pemantauan atas kondisi bantalan gelinding menjadi sesuatu yang penting untuk didiagnosis. Proses diagnosis dilakukan dengan menggunakan data sinyal getaran dari bantalan gelinding. Data sinyal getaran yang didapatkan sudah melewati proses *preprocessing* . dengan adanya diagnosis kerusakan tersebut diharapkan dapat memudahkan tindakan ataupun perlakuan terhadap mesin, sehingga nantinya dapat meningkatkan efektifitas, efisiensi pada kinerja mesin.

Diterapkan sebuah algoritma pembelajaran baru untuk pembangunan dan pelatihan jaringan saraf fungsi basis radial, dimana algoritmanya berdasarkan pada mekanisme global dari parameter pembelajaran yang menggunakan sebuah kemungkinan dari pendekatan klasifikasi (Zhu et al., 1998). Penelitian selanjutnya menggunakan teknik data mining dan visualisasi numerik untuk diagnosis dan prognosis pada objek data getaran bantalan gelinding yang memberikan pemahaman komprehensif dari sekumpulan data getaran yang besar (Blair dan Shirkhodaie, 2001).

Pendeteksian awal dari kerusakan bantalan gelinding sangat penting dilakukan, untuk itu suatu *moment* statistik yang baru diusulkan (Niu et al., 2005). Sebuah deskripsi terpadu dari normalisasi statistik disajikan, dimana didalam rumusnya, persamaan *moment* merupakan nilai riil, yang membuat lebih fleksibel untuk pengoperasian dilapangan. Kemudian pendekatan baru dalam jaringan saraf fungsi basis radial untuk pemodelan kernel disajikan. Metode ini memberikan fleksibilitas untuk struktur kernel. Fleksibilitas berasal dari penggunaan fungsi pengubah yang diterapkan pada prosedur perhitungan yang penting untuk evaluasi kernel (Falcao et al., 2006). Penerapan klasifikasi menggunakan Transformasi Hilbert dan jaringan saraf tiruan (JST) untuk mengelompokkan gangguan kualitas daya juga

diteliti. Fitur yang diperoleh dari Transformasi Hilbert mudah dipahami dan kebal terhadap *noise* atau kebisingan. Kemudian fitur tersebut diberikan pada jaringan saraf fungsi basis radial untuk pengembangan jaringan (Jayasree et al., 2009).

Yang membedakan dari penelitian sebelumnya adalah disini peneliti akan mendiagnosis kerusakan bantalan gelinding berbasis fitur statistik dengan metode *Radial Basis Function Neural Network* (RBFNN). Metode ini digunakan untuk mengklasifikasikan kerusakan kedalam kelas-kelas tertentu. RBFNN mentransformasikan input secara non linier pada *hidden layer* yang selanjutnya diproses secara linier pada *output layer*. Penggunaan metode ini dianggap tepat karena memiliki keunggulan karena membuat perhitungan matematis menjadi sederhana, yang hanya merupakan sebuah aljabar linier yang relatif mudah, jadi tidak ada optimasi dari algoritma turunan. kelebihan ini dianggap penulis dapat memudahkan dalam proses perhitungannya yang cukup kompleks.

Berdasarkan latar belakang tersebut dapat dirumuskan masalah dalam penelitian ini, yaitu bagaimana mendiagnosis kerusakan bantalan gelinding pada mesin industri dengan pendekatan statistik berbasis fitur dengan metode *Radial Basis Function Neural Network* (RBFNN).

1.2 Tujuan Penelitian

Adapun tujuan penelitian ini adalah menerapkan metode RBFNN dalam mendiagnosis kerusakan bantalan gelinding dan melihat tingkat akurasi dari penggunaan metode tersebut yang dapat digunakan sebagai penunjang pengambilan keputusan.

1.3 Manfaat Penelitian

- a. Menghemat biaya operasional mesin jika kerusakan yang terjadi pada mesin dapat didiagnosis dengan cepat dan tepat.
- b. Meminimalkan jadwal penghentian karena perbaikan.
- c. Sistem cerdas yang dihasilkan dapat digunakan sebagai penunjang pengambilan keputusan.

BAB II

TINJAUAN PUSTAKA DAN DASAR TEORI

2.1 Tinjauan Pustaka

Sebuah algoritma pembelajaran untuk jaringan saraf *Radial Basis Function* (RBF) disajikan dalam penelitian ini. Jumlah *neuron* RBF dan jumlah koneksi bobot ditentukan melalui pembelajaran. Algoritma pembelajarannya berbeda dengan *Self-Organizing-Feature* dari jaringan Adaptive Resonance Theory (ART). Proses pembelajaran tanpa pelatihan digunakan dalam jaringan ART, sementara RBF melibatkan proses pembelajaran dengan pelatihan. Selain itu pada algoritma ini konfigurasi jaringan dan koneksi bobot diketahui dengan menerapkan mekanisme evaluasi global statistik dari distribusi sampel pelatihan dalam ruang pola multidimensi. Peneliti menggambarkan sebuah struktur jaringan saraf bernama C-RBF beserta informasi global berbasis algoritma pembelajaran. Kinerja jaringan dan proses pembelajarannya ditingkatkan dengan menambah lapisan kompetitif di tengah jaringan RBF. Struktur baru ini meringankan beban pembelajaran untuk optimasi fungsional dan lapisan asosiasi linier. Lapisan kombinasi linier dari jaringan RBF yang umum biasanya memperlambat pengoperasian, hal ini disebabkan karena prosedur iteratif berbasis prosedur gradien turunan yang umumnya diterapkan. Dengan adanya pembelajaran C-RBF permasalahan ini tidak ada lagi. Lapisan kombinasi linear dihilangkan dan digantikan dengan operasi bersama logika. Struktur jaringan RBF juga memfasilitasi konstruksi dan pelatihan jaringan tambahan (Zhu et al., 1998).

Selain itu penelitian dalam penggunaan data mining dan teknik visualisasi numerik untuk diagnosis dan prognosis dari data getaran bantalan juga dilakukan. Dengan menggunakan teknik ini pemahaman yang komprehensif dari sekumpulan data getaran yang besar dapat dicapai. Pendekatan ini menggunakan agen cerdas

untuk mengisolasi karakteristik getaran bantalan gelinding tertentu dengan menggunakan analisis statistik dan pemrosesan sinyal untuk kompresi data. Hasil dari kompresi data ini bisa divisualisasikan dalam plot 3-D yang digunakan untuk melacak sumber dan perkembangan dari kerusakan getaran data bantalan gelinding. Paket perangkat lunak untuk pemantauan kondisi mesin telah dikembangkan dengan banyak modul fungsional untuk analisis beban dan diagnosis kerusakan bantalan gelinding, namun perlu adanya pengembangan untuk melacak kecenderungan dan korelasi dari kerusakan yang berbeda atau keganjilan tertentu tentang kondisi mesin, sehingga dapat memaksimalkan proses diagnosis dan prognosis dari bantalan gelinding (Blair dan Shirkhodaie, 2001).

Moment statistik yang baru untuk pendeteksian dini dari bantalan gelinding disajikan dalam penelitian ini. Sebuah deskripsi terpadu dari normalisasi statistik juga diusulkan. Didalam persamaannya nilainya dijadikan riil, hal ini bertujuan untuk membuat nilai lebih fleksibel sehingga memudahkan dalam pengoperasian dilapangan. Pendekatan yang disajikan ini memberikan lebih banyak fleksibilitas untuk memilih moment statistik yang tepat untuk mendeteksi kerusakan bantalan gelinding. Moment statistik yang dinormalisasi NM_a^2 dan M_a^3 dibandingkan dengan moment ke 3 (S) dan moment ke 4 (K). Hasil dari simulasi dan tes percobaan menunjukkan bahwa dua parameter statistik baru NM_a^2 dan NM_a^3 menunjukkan hasil yang hampir sama dengan parameter statistik sebelumnya S dan K.

Berikut adalah persamaan yang digunakan untuk penambahan moment statistik yang baru.

$$NM_a^2 = \frac{\frac{1}{N} \sum_{k=1}^N (y_k)^2}{\left[\frac{1}{N} \sum_{k=1}^N (y_k) \right]^2} = \frac{\frac{1}{N} \sum_{k=1}^N |x_k|^2}{\left[\frac{1}{N} \sum_{k=1}^N |x_k| \right]^2} = \frac{\frac{1}{N} \sum_{k=1}^N (x_k)^2}{\left[\frac{1}{N} \sum_{k=1}^N (x_k) \right]^2} \quad (2.1)$$

$$NM_a^3 = \frac{\frac{1}{N} \sum_{k=1}^N (y_k)^3}{\left[\frac{1}{N} \sum_{k=1}^N (y_k) \right]^3} = \frac{\frac{1}{N} \sum_{k=1}^N |x_k|^3}{\left[\frac{1}{N} \sum_{k=1}^N |x_k| \right]^3} \quad (2.2)$$

$$NM_s^{3/2} = \frac{\frac{1}{N} \sum_{k=1}^N (y_k)^{3/2}}{\left[\frac{1}{N} \sum_{k=1}^N (y_k) \right]^{3/2}} = \frac{\frac{1}{N} \sum_{k=1}^N ((x_k)^2)^{3/2}}{\left[\frac{1}{N} \sum_{k=1}^N (x_k)^2 \right]^{3/2}} = \frac{\frac{1}{N} \sum_{k=1}^N |x_k|^3}{\sigma^3} \quad (2.3)$$

$$NM_s^2 = \frac{\frac{1}{N} \sum_{k=1}^N (y_k)^2}{\left[\frac{1}{N} \sum_{k=1}^N (y_k) \right]^2} = \frac{\frac{1}{N} \sum_{k=1}^N ((x_k)^2)^2}{\left[\frac{1}{N} \sum_{k=1}^N (x_k)^2 \right]^2} = \frac{\frac{1}{N} \sum_{k=1}^N |x_k|^4}{\sigma^4} \quad (2.4)$$

Dimana NM_a^2 dan NM_a^3 adalah dua normalisasi *moment* statistik, $NM_s^{3/2}$ dan NM_s^2 adalah Skewness, yang didapatkan dari nilai absolute dan kurtosis. N adalah panjang data, dan $(Y_k)/(X_k)$ adalah Data (Niu et al., 2005).

Penelitian ini mengusulkan sebuah arsitektur yang dimodifikasi guna menambah fleksibilitas untuk pemodelan kernel RBF. Penerapan arsitektur yang baru mampu menyelesaikan masalah klasifikasi yang sulit dengan hasil yang baik. Jumlah dan fungsi kernel yang tepat ditentukan oleh prosedur iteratif, dimana sebagian besar parameter diatur menggunakan data latih. Prosedur akhir pelatihan hanya perlu menyesuaikan sebaran parameter untuk setiap kernel. Hal ini memberikan performa pengklasifikasian yang bagus. Keuntungan lain dari metode yang diusulkan ini yaitu kesederhanaan metode itu sendiri memudahkan penyebaran dan penggunaan pada masalah tertentu (Falcao et al., 2006).

Pada makalah ini telah dilakukan upaya untuk mengekstrak fitur yang efisien dari gangguan kualitas daya menggunakan transformasi Hilbert dan untuk mengklasifikasikan sinyal menggunakan jaringan saraf fungsi basis radial. Fitur yang

diekstraksi dari transformasi Hilbert sangat sederhana, namun sangat efektif. Jaringan saraf RBF memakan waktu yang sedikit tetapi akurasi klasifikasinya sangat tinggi. Fitur tersebut kemudian dibandingkan dengan *wavelet transform* dan *s-transform*. *Wavelet transform* memiliki kemampuan mengekstrak fitur dari sinyal dalam domain waktu dan frekuensi dalam bersamaan, namun juga menunjukkan beberapa kelemahan seperti perhitungan yang berlebihan, dan peka terhadap tingkat kebisingan. Berbeda dengan transformasi Hilbert, yang dapat dihitung dengan cepat. Selain itu metode ini menunjukkan sensitivitas rendah terhadap suara dan menghasilkan akurasi klasifikasi lebih baik bahkan pada lingkungan yang bising (Jayasree et al., 2009).

2.2 Dasar Teori

2.2.1 Bantalan Gelinding



Gambar 2.1 Bantalan Gelinding (Bearing)

Bantalan gelinding (*bearing*) adalah suatu bagian atau komponen yang berfungsi untuk menahan/mendukung suatu poros agar tetap pada kedudukannya. Bearing mempunyai elemen yang berputar dan bagian yang diam saat bekerja yang terletak antara poros dan rumah *bearing*.

Ada 3 bagian utama *bearing* yaitu:

- a. Elemen yang berputar (*ball, cylinder, barrels, taper, needle*) selalu dipasang pada jarak yang telah ditentukan dan letaknya selalu dalam “sangkaranya”.
- b. Cincin dalam (*inner race*) merupakan bagian yang berputar dan kecepatan putarnya sama dengan poros.
- c. Cincin luar (*outer race*) merupakan bagian yang diam dan dipasang pada lubang.

2.2.2 Pemantauan Kondisi Getaran

Pengumpulan data pengukuran getaran mesin untuk pemantauan kondisi bantalan gelinding dimaksudkan untuk meningkatkan konsistensi prosedur pengukuran. Pemantauan getaran tersebut dilakukan untuk membantu dalam evaluasi “kesehatan” mesin secara terus menerus. Berdasarkan jenis mesin dan komponen penting yang di pantau. Satu atau lebih parameter pengukuran dan system pemantauan yang sesuai harus dipilih, tujuannya untuk mengenali kondisi “tidak sehat” pada mesin sehingga masih ada waktu yang cukup untuk mengambil tindakan sebelum terjadi kerusakan yang signifikan pada suku cadang mesin yang dapat mengurangi pengoperasian peralatan dan proyeksi umur mesin atau berhenti total.

Beberapa manfaat dari pemantauan kondisi mesin dan diagnosis kerusakan adalah sebagai berikut:

- a. Meningkatkan keandalan mesin
- b. Meningkatkan efisiensi dalam pengoperasian
- c. Meningkatkan manajemen resiko (mengurangi penghentian)
- d. Mengurangi biaya pemeliharaan
- e. Mengurangi persediaan suku cadang
- f. Meningkatkan pengetahuan tentang kondisi mesin
- g. Memperpanjang operasional umur mesin
- h. Menghapus kegagalan kronis.

2.2.3 Pengukuran Getaran


Secara umum ada tiga jenis pengukuran yang dapat digunakan untuk pemantauan kondisi getaran pada mesin yaitu (ISO 13373-1-2002) :

- a. Pengukuran getaran yang dilakukan pada struktur non-berputar mesin, seperti tempat bantalan gelinding, *casing* mesin atau bantalan gelinding.
- b. Gerakan relatif antara bantalan rotor dan bantalan statis
- c. Pergerakan getaran absolut dari elemen yang berputar.


Pengukuran getaran dilakukan menggunakan akselerometer. Akselerometer adalah transduser yang berfungsi untuk mengukur percepatan, mendeteksi dan mengukur getaran, ataupun untuk mengukur percepatan akibat gravitasi bumi.

Pengukuran getaran pada struktur biasanya akan menggunakan r.m.s perputaran yang sering dikombinasikan dengan r.m.s perpindahan atau percepatan. Jika getaran didominasi *sinusoidal* perpindahan getaran juga bisa digunakan (*zero-to-peak* atau *peak to peak*) juga bisa digunakan.

Pengukuran getaran dilakukan pada mesin dengan memasang sensor akselerometer pada posisi arah vertikal dan horisontal. Pada mesin dengan poros horisontal, posisi arah vertikal (y) dan horisontal (x) tegak lurus dengan sumbu poros mengukur getaran radial, sedangkan posisi horisontal (z) sejajar dengan sumbu poros mengukur getaran aksial. Cara pemasangan sensor akselerometer pada mesin jenis ini ditunjukkan pada Gambar 2.2. Pada mesin dengan poros vertikal, sensor akselerometer dipasang pada posisi horisontal (x dan y) untuk mengukur getaran radial, sedangkan pada arah vertikal (z) dipakai untuk mengukur getaran aksial. Pengukuran mesin jenis vertikal ditunjukkan pada Gambar 2.3.



Gambar 2.2 Pemasangan sensor getaran pada rumah bantalan dengan posisi sumbu mesin horisontal (ISO 13373)



Gambar 2.3 Pemasangan sensor getaran pada rumah bantalan dengan posisi sumbu mesin vertikal (ISO 13373)

Keterangan :

x : posisi horisontal

y : posisi vertikal

z : posisi aksial

2.2.4 Format Presentasi Data

Data untuk pemantauan kondisi getaran mesin dianalisis dan disajikan dalam banyak format dasar, diantaranya analisis frekuensi spektrum, frekuensi diskrit, tren frekuensi diskrit data spectral, tren frekuensi-band yang terbatas, analisis waterfall, analisis vector, dan analisis poros orbit.

2.2.5 Data Mining Getaran

Data mining merupakan prinsip dasar dalam mengurutkan data dalam jumlah yang sangat banyak dalam hal ini data getaran, dan mengambil informasi-informasi yang berkaitan dengan apa yang diperlukan yang digunakan untuk proses analisis. Selain itu data mining disini mengidentifikasi tren yang terdapat pada sekumpulan data getaran, melakukan pembersihan data untuk menghilangkan data yang tidak konsisten, evaluasi pola untuk menemukan pola yang menarik, dan presentasi pengetahuan dengan teknik visualisasi.

Dorongan data mining ini sangat berguna agar memahami dengan baik data, dalam hal ini kecendrungan pusat data, variasi dan sebaran. Kemudian dimensi numeriknya diurutkan sesuai intervalnya, lalu sebaran data dianalisis dengan digranularities oleh beberapa presisi dan boxplot dari analisis kuantil interval yang diurutkan. Untuk analisis penyebaran pada perhitungan komputasi dilakukan dengan melipat langkah ke dimensi numeric dan *boxplot* atau analisis kuantil pada kubus yang ditransformasikan.

2.2.6 Data Preprocessing

Data preprocessing merupakan pembersihan terhadap data yang sudah diukur sebelum nantinya data tersebut diproses. Hal ini bertujuan untuk membuat data menjadi lebih berkualitas. Langkah-langkah utama dari data preprocessing yaitu:

- a. Pembersihan data, yaitu membersihkan data dari noisy, mengidentifikasi data dari yang tidak penting dan menyelesaikan masalah inconsistensi data.
- b. Intergrasi data, yaitu menggabungkan dari beberapa database yang saling berhubungan menjadi satu.
- c. Transformasi data, yaitu normalisasi dan agregasi data.
- d. Reduksi data, yaitu mengurangi volum data namun tetap mempertahankan arti dalam hal analisis data.
- e. Diskritasi data, yaitu merupakan bagian dari reduksi data, dengan memperhitungkan data yang signifikan. khususnya pada data numerik.

2.2.7 Deskriptif Statistik

Deskriptif Statistik adalah metode-metode yang berkaitan dengan pengumpulan dan penyajian suatu gugus data sehingga memberikan informasi yang berguna. Deskripsi statistik ini berkenan dengan deskripsi data misal menghitung rata-rata dan varians dari suatu data, mendeskripsikan menggunakan table-tabel atau grafik sehingga data mentah lebih mudah dibaca dan lebih bermakna .

Analisis frekuensi merupakan analisis yang mencakup gambaran frekuensi data secara umum seperti mean, media, modus, deviasi, standar, varian, minimum, maksimum dan sebagainya.

2.2.8 Ekstraksi Fitur

Feature extraction (ekstrasi fitur) merupakan tahap yang penting dalam system pengenalan, dimana performa klasifikasi bergantung langsung pada seleksi fitur dan ekstraksi. Manfaat utama dari ekstraksi fitur adalah menghilangkan

redundancy atau pengulangan data yang merepresentasikan sebuah bentuk karakter oleh satu set fitur numeric (Wiley, 2005).

Ekstraksi fitur berfungsi untuk mendapatkan fitur sebuah karakter. Sebagai pengklasifikasi digunakan untuk identifikasi kesalahan lebih lanjut. Oleh karena itu ekstraksi fitur ini harus menjaga informasi yang penting dalam membuat keputusan, dalam hal ini keputusan dalam mendiagnosis kesalahan ataupun kerusakan yang terjadi. Pengurangan dimensi waktu dari ruang fitur dan mempermudah jumlah contoh pelatihan dan jumlah waktu yang diperlukan untuk pelatihan tersebut.

2.2.9 Seleksi Fitur

Seleksi fitur salah satu metode pengolahan awal data (*pre-processing*) untuk menentukan subset fitur yang akan diolah pada tahap berikutnya. Seleksi fitur mereduksi jumlah fitur dan menghilangkan data yang tidak relevan. Data yang tidak relevan atau *outlier* merupakan suatu nilai dari pada sekumpulan data yang berbeda dibandingkan data lainnya serta tidak menggambarkan karakteristik data tersebut.

Fitur ekstraksi dan fitur seleksi adalah dua pendekatan yang berbeda untuk pengurangan dimensi. ekstraksi fitur melibatkan transformasi linear atau nonlinear dari ruang fitur asli ke dimensi baru yang lebih rendah. Walaupun itu tidak mengurangi dimensi dari vektor diumpankan ke *classifier*, jumlah fitur yang diukur tetap sama, sedangkan seleksi fitur langsung mengurangi jumlah fitur asli dengan memilih *subset* dari fitur tersebut yang masih mempertahankan cukup informasi untuk proses klasifikasi (Liu and Zheng, 2006).

Tujuan seleksi fitur adalah sebagai berikut:

- a. Menyederhanakan proses ekstraksi fitur
- b. Meningkatkan akurasi
- c. Meningkatkan keandalan dari estimasi performa

2.2.10 *Principal Component Analysis (PCA)*

PCA merupakan alat analisis data untuk mengidentifikasi pola-pola dalam data yang menyorot persamaan dan perbedaan dari data (Smith,2002). PCA digunakan untuk mereduksi sebuah himpunan asli variabel kedalam himpunan data yang lebih kecil yang tidak berkorelasi dan mewakili sebagian informasi pada himpunan variabel asli. PCA merupakan suatu teknik statistik untuk mengubah dari sebagian besar variabel asli yang digunakan yang saling berkorelasi satu dengan yang lainnya menjadi satu set variabel baru yang lebih kecil dan saling bebas (tidak berkorelasi lagi). Keuntungan PCA adalah mengurangi jumlah dimensi data tanpa mengurangi informasi dari data tersebut.

Principal component analysis (PCA) adalah kombinasi linier tertentu dari D dimensi acak $X_j(j \in \{1,2,\dots,D\})$. Secara geometris kombinasi linier ini merupakan sistem koordinat baru yang didapat dari rotasi sistem semula. Koordinat baru tersebut merupakan arah dengan variabilitas maksimum dan memberikan kovariansi yang lebih sederhana. PCA lebih baik digunakan jika variabel-variabel asal saling berkorelasi. PCA merupakan penyelesaian masalah eigen yang secara matematis ditulis dalam persamaan :

$$Cv = \lambda v \quad (2.5)$$

yang mana variabilitas suatu dataset yang dinyatakan dalam matriks kovariansi C dapat digantikan oleh suatu scalar tertentu λ tanpa mengurangi variabilitas asal secara signifikan.

Diberikan dataset matrix X berukuran $(n \times D)$ yang terdiri dari n observasi $X_i(i \in \{1,2,\dots,n\})$ dengan D dimensi. Algoritma PCA adalah sebagai berikut:

1. Hitung vektor rata-rata $\bar{x}_j(j \in \{1,2,\dots,D\})$ dengan

$$\bar{x}_j = \frac{\sum_{i=1}^n x_{i,j}}{n} \quad (2.6)$$

2. Hitung matriks kovariansi C atau $\text{cov}(X)$ dengan

$$C = \text{cov } x_k, x_j = \frac{\sum_{i=1}^n (x_{ik} - \bar{x}_k)(x_{ij} - \bar{x}_j)}{n-1} \quad (2.7)$$

3. Hitung nilai eigen λ dengan vektor eigen v yang memenuhi persamaan:

$$|c - \lambda I| = 0 \quad (2.8)$$

dan

$$|c - \lambda I|v = 0 \quad (2.9)$$

4. Vektor eigen yang didapatkan merupakan komponen utama untuk membentuk variabel baru. Variabel-variabel baru merupakan perkalian antara vektor eigen v dengan matriks X_a yaitu matriks X telah dinormalisasi (adjusted) yang dihitung dengan rumus :

$$X_{ai} = \frac{(x_i - \bar{x})}{s_i} \quad (2.10)$$

5. Sedangkan variansi yang dapat dijelaskan oleh variabel baru ke- i tergantung persentase kontribusi p_i dari masing-masing nilai eigen, yang dihitung dengan rumus :

$$p_i = \frac{\lambda}{\sum_{j=1}^D \lambda_j} \times 100\% \quad (2.11)$$

Untuk penentuan jumlah variabel baru yang digunakan tergantung persentase kontribusi kumulatif dari kumulatif nilai eigen yang telah diurutkan dari nilai yang terbesar. Nilai persentase kontribusi kumulatif sampai komponen ke - r dihitung dengan rumus :

$$pk_r = \frac{\sum_{j=1}^r \lambda_j}{\sum_j \lambda_j} \times 100\% \quad (2.12)$$

Dengan $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_D$

Diberikan dataset matrik X berukuran ($n \times D$) yang terdiri dari n observasi x_i ($i \in \{1, 2, \dots, n\}$) dengan D dimensi. Teknik reduksi dimensi adalah sebagai berikut:

1. Lakukan partisi dimensi himpunan X menjadi ℓ himpunan bagian, sehingga masing-masing x_i menjadi berukuran d dimensi dengan

$$d = \frac{D}{\ell} \quad (2.13)$$

2. Lakukan untuk setiap subset data dengan @ dimensi sebagai berikut :
 - a. Hitung matriks kovariansi masing-masing subset menurut persamaan (2.7).
 - b. Hitung nilai eigen dan vektor eigen masing-masing subset menurut persamaan (2.8) dan (2.9).
 - c. Ambil vektor eigen v dengan nilai eigen terbesar, di mana $\lambda^* = \max\{\lambda_1, \lambda_2, \dots, \lambda_d\}$.
 - d. Lakukan perhitungan observasi baru x^* berukuran $(n \times 1)$ menggunakan:

$$x^* = (v^T x_a^T)^T \text{ atau } x^* = (x_a v)^T \quad (2.14)$$
 dengan x_{ai} ($i \in \{1, 2, \dots, n\}$) adalah data normalisasi dan v_j ($j \in \{1, 2, \dots, d\}$) adalah vektor eigen yang mempunyai variansi maksimum.
3. Gabungkan observasi baru menjadi dataset baru X^* berukuran $(n \times \ell)$.

2.2.11 Proses Klasifikasi

Proses klasifikasi pada penelitian ini adalah mengelompokkan fitur-fitur berdasarkan kesamaan ciri kedalam kelas-kelas tertentu. Klasifikasi bertujuan untuk menetapkan pola-pola yang tak terlihat sebelumnya (Orr, 1996). Klasifikasi pada penelitian dibedakan menjadi 8 kelas yang berarti 8 jenis kerusakan yang umumnya terjadi pada bantalan gelinding suatu mesin.

2.2.11.1 Radial Basis Function Neural Network (RBFNN)

Model jaringan saraf fungsi basis radial adalah model jaringan saraf dengan satu unit dalam lapisan tersembunyi. Jaringan saraf fungsi basis radial merupakan jaringan saraf feed forward bersifat khusus yakni mentransformasikan input secara non linier pada hidden layer yang selanjutnya diproses secara linier pada output layer.

RBFNN dapat diaplikasikan ke berbagai domain permasalahan antara lain seperti pemodelan data time series, pengklasifikasian, pengenalan suara, restorasi gambar, estimasi gerak dan segmentasi benda bergerak (Purwitasari et al.,2011). Pada penelitian ini akan dibahas penggunaan RBFNN untuk pengklasifikasian.

2.2.11.2 Fungsi Basis Radial

RBFNN didesain untuk membentuk pemetaan nonlinier dari variable input ke unit hidden layer dan pemetaan linear dari hidden layer ke output. Sehingga pada RBFNN dilakukan pemetaan input dari ruang berdimensi p ke output ruang berdimensi 1.

$$s: \mathcal{R}^p \rightarrow \mathcal{R}^1 \quad (2.15)$$

Berdasarkan teori interpolasi multivariate : jika diberikan N buah titik yang berbeda $\{x_i \in \mathcal{R}^p \mid i=1,2,\dots,N\}$ yang berhubungan dengan N buah bilangan real $d_i \in \mathcal{R}^1 \mid i=1,2,\dots,N\}$, maka fungsi $F : \mathcal{R}^p \rightarrow \mathcal{R}^1$ adalah fungsi yang memenuhi $F(x_i) = d_i, i = 1,2,\dots,N$.

Agar memenuhi teori diatas, interpolasi dengan menggunakan fungsi $F(x)$ harus meloloskan semua data. Teori interpolasi multivariate secara ringkas dapat dinyatakan dengan

$$\begin{aligned} F: \mathcal{R}^p &\rightarrow \mathcal{R}^1 \\ F(x_i) &= d_i, i = 1,2 \dots N \end{aligned} \quad (2.16)$$

Ada beberapa fungsi basis radial, diantaranya adalah Fungsi Thin Plate Spline, Fungsi Multikuadratik, Fungsi Invers Multikuadratik dan Fungsi Gaussian.

Fungsi basis radial yang dipilih adalah fungsi Gaussian, dikarenakan mempunyai sifat lokal, yaitu bila input dekat dengan rata-rata (pusat), maka fungsi akan menghasilkan nilai 1, sedangkan bila input jauh dari rata-rata maka fungsi akan

memberikan nilai nol (Orr,1996). Selain itu fungsi Gaussian merupakan salah satu fungsi basis radial yang memberikan hasil terbaik dalam pengenalan pola.

Adapun persamaan dari fungsi Gaussian adalah sebagai berikut:

Fungsi Gaussian

$$\phi(z) = \exp\left[-\frac{(z-\mu)^2}{\sigma^2}\right] \quad (2.17)$$


Dimana, z adalah data, μ adalah means dan σ adalah varian/ standar deviasi.

Sebelum masuk pada pencarian output layer, jarak euclidean harus dicari terlebih dahulu dengan persamaan sebagai berikut :

$$\text{Dist}(i,k) = \sqrt{\sum_{i=k}^D (i_j - k_j)^2} \quad (2.18)$$

Dimana, $\text{dist}(i,k)$ adalah jarak euclidean antara vektor i dan vektor k. I_j adalah komponen ke j dari vector i, k_j adalah komponen ke j dari vector k. Sedangkan D adalah jumlah komponen pada vektor i dan vektor k.

Berikut adalah arsitektur RBFNN :



Gambar 2.4 Arsitektur RBFNN (Zhu et al., 1998)

Pada pemodelan RBFNN dilakukan dengan memilih suatu fungsi $F(x)$ sehingga persamaan (2.16) dipenuhi. Interpolasi input-output (2.16) dengan melihat disain model RBFNN (gambar 2.4), maka output dapat didefinisikan dengan persamaan (2.19)

$$y = F(x) = \exp[-\|x - c_i\|^2 / (\sigma^2)] \quad (2.19)$$

Dimana x adalah input vektor dari jaringan, c_i adalah vector center ke- i , maka $\|x - c_i\|$ adalah jarak antara input vector ke pusat vector. $\|\cdot\|$ adalah norm jarak euclidean, sedangkan y adalah output dari fungsi basis radial.

Bobot dari neuron antara hidden dan output neuron dihitung menggunakan persamaan (2.20). Dimana pseudo invers memiliki peran yang sama sebagai jaringan dengan metode least mean square (LMS).

$$y = WA(x, c), W = yA^T(AA^T)^{-1} \quad (2.20)$$

W adalah bobot matriks, A adalah output dari hidden layer dan y adalah keluaran dari output layer.

RBFNN melakukan klasifikasi dengan mengukur jarak input dengan pusat dari neuron yang tersembunyi pada fungsi basis radial. RBFNN bekerja lebih cepat dibanding dengan back propagation yang memakan waktu. Selain itu RBFNN tepat digunakan untuk data berukuran besar.

RBFNN memiliki keunggulan yaitu :

1. Cocok digunakan untuk data training yang besar, karena tidak memperlambat kemampuannya.
2. Bisa digunakan untuk menggabungkan hasil dari *multiple classifier*.
3. Dapat mengintegrasikan metode deteksi, baik *misuse* maupun *anomaly* pada jaringan fungsi basis radial yang hierarkial.
4. Struktur jaringan sederhana sehingga mempercepat proses pembelajaran.

Adapun kekurangan RBFNN yaitu:

RBFNN memiliki basis fungsi yang sangat sedikit, generalisasi yang tidak begitu baik, terlalu fleksibel, sehingga menyebabkan terjadinya noise pada saat pelatihan. Hal ini dapat menyebabkan kesalahan prediksi (Jili dan Ning, 2007).