

Penerapan Metode *Support Vector Machine (Svm)* Untuk Diagnosis Kerusakan Pada Bantalan Gelinding

Dwi Nor Amadi¹⁾

¹⁾ Dosen Fakultas Teknik Universitas Merdeka Madiun

email : dwinor@unmer-madiun.ac.id

Abstract :

Rolling element bearing fault on industrial machine can cause a serious problem in that industry because the whole production process will shut down in a few times or days. That condition can cause a big losses on that company. Therefore, in this study the researchers will implement the support vector machine method to build an intelligent system for diagnosing rolling element bearing fault. so the rolling element bearing can be repaired or replaced before total damage occurs. The benefit are the company can minimize the losses caused by rolling element bearing fault. The vibration data from the Rolling element bearing will be extracted by using feature extraction to define a mapping the data from the original representation space into a new space where the classes are more easily separable and then the data will be processed with support vector machine method. After that, we can analyze the result to diagnose the rolling element bearing condition.

Keywords : *Intelligent System, Rolling Element Bearing Fault, SVM.*

Pendahuluan

Bantalan gelinding merupakan sebuah komponen yang tidak bisa lepas dari mesin, baik itu mesin untuk industri maupun mesin untuk transportasi. Bantalan gelinding itu sendiri pada dasarnya merupakan suatu elemen mesin yang digunakan untuk menahan poros berbeban, beban tersebut dapat berupa beban aksial atau beban radial. tipe bantalan gelinding yang digunakan untuk bantalan disesuaikan dengan fungsi dan kegunaannya.

Bantalan gelinding sendiri dibedakan menjadi dua macam yaitu journal bearing dan thrust bearing, dimana journal bearing berfungsi untuk menahan beban radial, beban tegak lurus dengan poros, biasanya untuk putaran tinggi dan beban yg besar, contohnya pada pompa, turbin dan kompresor. Sedangkan thrust bearing berfungsi untuk menahan beban aksial pada poros, beban tegak lurus terhadap poros. karena fungsi utama

bantalan gelinding adalah harus mampu menahan beban statis dan dinamis seringkali bantalan gelinding tersebut tidak bekerja dengan optimal dikarenakan beban yang berlebihan, umur pemakaian, panas berlebihan yang jika dibiarkan akan menimbulkan kerusakan dan biaya yang besar,

Untuk menekan biaya dan kerusakan tersebut maka perlu dibuat sebuah sistem cerdas untuk mendiagnosis kerusakan pada bantalan gelinding tersebut. Diharapkan dengan sistem cerdas untuk mendiagnosis kerusakan bantalan gelinding ini perusahaan dapat meningkatkan efektifitas dan efisiensinya sehingga dapat meningkatkan hasil atau keuntungan yang lebih baik.

Metode yang digunakan dalam penelitian ini adalah support vector machine. Dimana metode tersebut adalah metode yang relatif baru digunakan, namun mampu memberikan hasil yang optimal dan

selalu sama untuk setiap proses. Dikarenakan support vector machine berusaha menemukan solusi global sehingga hasil yang dicapai selalu sama di setiap proses. Dalam teknik ini, support vector machine berusaha untuk menemukan fungsi pemisah yang optimal yang bisa memisahkan dua set data dari dua kelas yang berbeda. Hal ini berbeda dengan penelitian – penelitian sebelumnya yang hanya menemukan solusi lokal dimana hasil yang dicapai dalam setiap proses berbeda dengan proses sebelumnya.

Tinjauan Pustaka

Diagnosis kerusakan adalah serangkaian proses yang terdiri dari

proses deteksi, proses isolasi dan proses identifikasi kerusakan yang terjadi dan yang akan terjadi ketika komponen yang di diagnosis tersebut masih beroperasi meskipun terjadi penurunan kinerja. Diagnosis dapat menjadi alat pelengkap untuk pengambilan keputusan, diagnosis juga bermanfaat untuk meningkatkan kinerja prognosis selain itu diagnosis juga berguna untuk memberikan umpan balik informasi untuk mendesain ulang sistem.

Bearing adalah bagian mesin dimana bagian-bagian mesin yang lain berputar atau bergeser. Bearing memiliki tiga fungsi utama :

1. mengurangi gesekan
2. menahan beban.




Gambar 1 Bantalan Gelinding

SVM sendiri sudah berkembang sejak tahun 1960, akan tetapi baru diperkenalkan oleh Vapnik, Boser dan Guyon pada tahun 1992 dan sejak itu SVM berkembang dengan pesat. Hal ini dikarenakan SVM merupakan salah satu teknik yang relatif lebih baru dibandingkan dengan teknik lain, tetapi memiliki kemampuan yang lebih baik di berbagai bidang aplikasi.

Linearly separable data merupakan data yang dapat dipisahkan secara linier. Misalkan $\{x_1, \dots, x_n\}$ adalah dataset dan $y_i \in \{+1, -1\}$ adalah label kelas dari data x_i . Pada gambar 1 dapat dilihat berbagai alternatif bidang pemisah yang dapat memisahkan semua data set sesuai dengankelasnya. Namun, bidang pemisah terbaik tidak hanya dapat memisahkan data tetapi juga memiliki margin paling besar.

A. SVM pada Linearly Separable Data



Gambar 2. Alternatif bidang pemisah (kiri) dan bidang pemisah terbaik dengan margin (m) terbesar (kanan)

Gambar 2 (kiri) memperlihatkan beberapa pola yang merupakan anggota dari dua buah kelas data yaitu +1 dan -1 yang di simbolkan dengan segi empat dan lingkaran. *Hyperlane* pemisah terbaik antara kedua kelas tersebut dapat di temukan dengan mengukur margin hyperlane tersebut dan mencari nilai maksimalnya. Margin adalah jarak antara *hyperline* tersebut dengan data masing masing kelas yang terdekat.

Pada gambar 2 (kanan) terlihat dua kelas dapat dipisahkan oleh sepasang bidang pembatas yang sejajar. Bidang pembatas pertama membatasi kelas +1 sedangkan bidang pembatas kedua membatasi kelas -1. sehingga diperoleh persamaan sebagai berikut.
 $x_i \cdot w + b \geq +1$ for $y_i = +1$
 $x_i \cdot w + b \leq -1$ for $y_i = -1$

SVM mencoba menemukan batas maksimal dari kedua kelas tersebut dan menempatkan garis margin ditengah dua batas maksimal kedua kelas tersebut. Data point yang digunakan untuk menunjukan margin tersebut bernama *support vector*. Ketika *support vector* sudah ditemukan maka fitur yang lain sudah tidak dibutuhkan karena support vector sudah berisi seluruh informasi untuk mendefinisikan klasifikasi. Geometri margin dapat di tentukan dengan $\|w\|^{-2}$ w adalah normal bidang dan b adalah posisi bidang relatif terhadap pusat koordinat.

B. SVM pada Nonlinearly Separable Data

Untuk mengklasifikasikan data yang tidak dapat dipisahkan secara linier formula SVM harus dimodifikasi karena tidak akan ada solusi yang ditemukan. dengan memperhitungkan noise dengan menggunakan slack variable ξ_i dan error pinalti dengan C sehingga dapat diperoleh solusi untuk masalah pada data yang tidak dapat dipisahkan secara linear dengan rumus sebagai berikut.

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^M \xi_i$$

Dimana ξ_i merupakan jarak antara margin dan x_i merupakan margin yang berada di sisi yang salah. Perhitungan dapat di buat lebih sederhana dengan mengkonversi masalah dengan kondisi khun-tacker menjadi sesuai dengan *lagrangian dual problem* sehingga dapat dihasilkan persamaan sebagai berikut

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^M \alpha_i y_i (w \cdot x_i + b) + \sum_{i=1}^m \alpha_i$$

Persamaan diatas digunakan untuk menyelesaikan masalah dual optimasi dengan diperoleh koefisien α_1 dimana koefisien tersebut dibutuhkan untuk mendapatkan nilai w untuk persamaan ini digunakan untuk menyelesaikan fungsi *non linear decision*.

SVM jugabisa di gunakan untuk menyelesaikan masalah pada klasifikasi non – linear dengan mengaplikasikan fungsi kernel. Data di klasifikasikan dengan cara memetakan keruang dimensional yang lebih tinggi dimanaklasifikasi linear bisa diselesaikan menggunakan fungsionon linear vector $\phi(x) = (\phi_1(x), \dots, \phi_n(x))$ untuk memetakan n dimensional input vector x kedalam 1 dimensional ruang fitur fungsi linear decision di dual form dapat dilihat pada persamaan berikut ini.

$$f(x) = \text{sign}(\sum_{i,j=1}^m \alpha_i y_i (\phi^T(x_i) \cdot \phi(x_j)) + b)$$

Bekerja dengan fitur ruang dimensi yang lebih tinggi tidak hanya memungkinkan fungsi ekspresi yang lebih kompleks tetapi juga dapat menghasilkan masalah. Masalah komputasi terjadi karena vector yang terlalu besar dan *over fitting* juga terjadi pada ruang fitur dengan dimensi yang tinggi. Masalah tersebut dapat di atasi menggunakan fungsi kernel.

Kernel merupakan fungsi yang mengembalikan *dot product* pemetaan ruangfitur dari data asli dinyatakan dengan $K(x_i, x_j) = \varphi^T(x_i) \cdot \varphi_j(x_j)$. Ketika mengaplikasikan fungsi kernel, pembelajaran di ruang fitur tidak membutuhkan evaluasi eksplisit φ sehingga fungsi pengambilan keputusan menjadi $f(x) = \text{sign}(\sum_{i,j=1}^m \alpha_i y_i K(x_i, x_j)) + b$

Fungsi apapun yang memenuhi teorema *Mercer's* (Vapnik, 1999) dapat digunakan sebagai fungsi kernel untuk menghitung *dot product* di ruang fitur. Ada beberapa fungsi kernel yang digunakan di SVM seperti linear, polynomial dan RBF kernel. Pemilihan kernel sangat penting untuk menyelesaikan masalah. Tabel 1. di bawah ini adalah fungsi dari kernel yang sering dipakai di SVM.

Tabel. 1 Fungsi kernel yang sering dipakai

Kernel	Persamaan
Linear	$K(x_i, x_j) = x_i^T x_j$
Polinomial	$K(x_i, x_j) = (\gamma \cdot x_i^T x_j + r)^p, \gamma > 0$
Radial basis function	$K(x_i, x_j) = \exp(-\gamma x_i - x_j ^2), \gamma > 0$

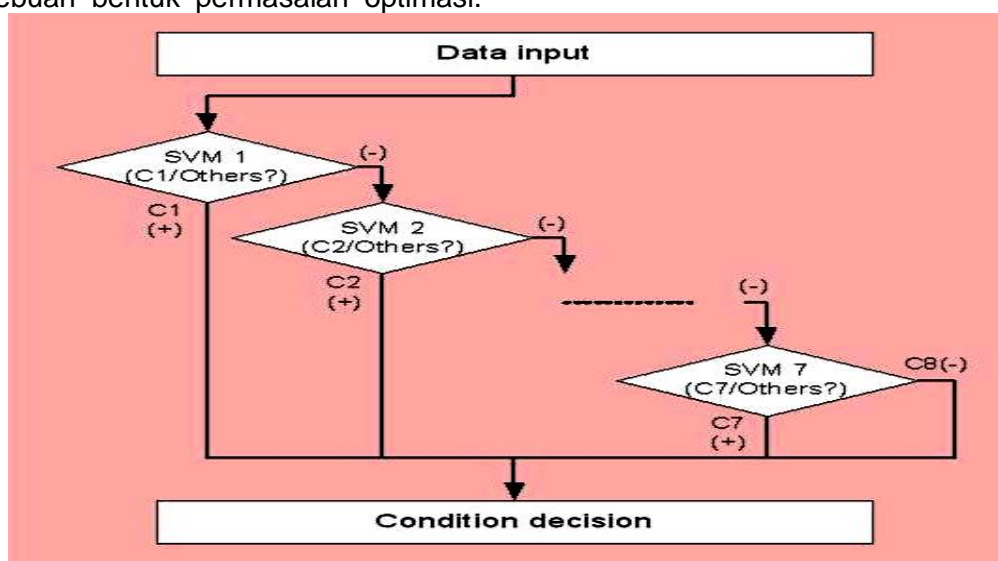
C. Multi Class SVM

SVM saat pertama kali diperkenalkan oleh Vapnik, hanya dapat mengklasifikasikan data ke dalam dua kelas (klasifikasi biner). Namun, penelitian lebih lanjut untuk mengembangkan SVM sehingga bisa mengklasifikasi data yang memiliki lebih dari dua kelas terus dilakukan. Ada dua pilihan untuk mengimplementasikan multi class SVM yaitu dengan menggabungkan beberapa SVM biner atau menggabungkan semua data yang terdiri dari beberapa kelas ke dalam sebuah bentuk permasalahan optimasi.

Namun, pada pendekatan yang kedua permasalahan optimasi yang harus diselesaikan jauh lebih rumit. Berikut ini adalah metode yang umum digunakan untuk mengimplementasikan multi class SVM dengan pendekatan yang pertama :

1. Metode "one-against-all".

Dengan menggunakan metode ini, dibangun k buah model SVM biner (k adalah jumlah kelas). Setiap model klasifikasi ke-i dilatih dengan menggunakan keseluruhan data, untuk mencari solusi permasalahan.

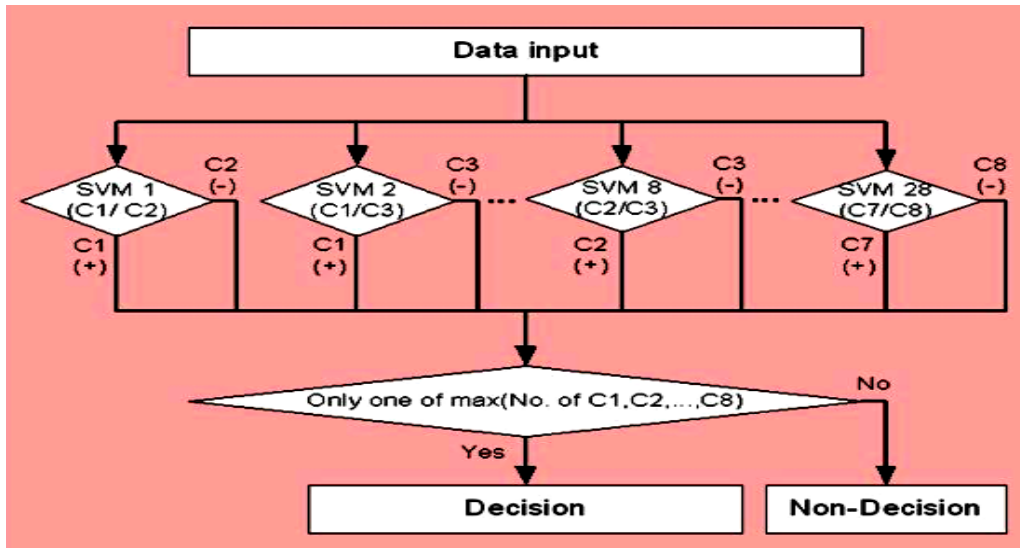


Gambar 3 Diagram alir data metode one-against-all

2. Metode "one-against-one".

Dengan menggunakan metode ini, dibangun $(k(k-1))/2$ buah model klasifikasi biner (k adalah jumlah kelas). Setiap model klasifikasi dilatih

pada data dari dua kelas. Untuk data pelatihan dari kelas ke- i dan kelas ke- j , dilakukan pencarian solusi untuk persoalan optimasi konstrain.



Gambar 4 Diagram Alir Data metode one-against-one

Metodologi

A. Alat Penelitian

Alat yang dipakai untuk penelitian ini adalah :

1. Hardware : seperangkat CPU dengan processor core i3 380M @2.53Mhz, memori 4GB, Hdd 320GB VGA 1GB Ati Radeon 5470 HD.
2. Software : Windows 7 Ultimate (64 bit), Matlab 7.10.0 R2009a dengan C++ compiler (64 bit)

B. Bahan Penelitian

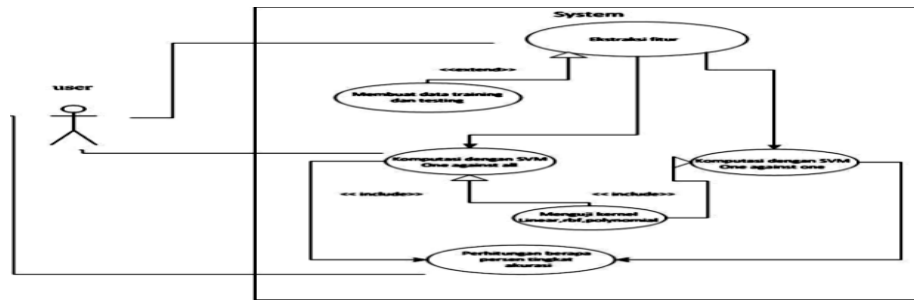
Bahan penelitian yang digunakan adalah data getaran bantalan gelinding undip berasal dari pengukuran getaran pada bantalan gelinding dengan metode pengumpulan data yang digunakan dalam penelitian ini adalah metode pengumpulan data periodik dimana pengukuran getaran pada bantalan gelinding diukur menggunakan sistem portabel dimana transducer tidak terpasang secara permanen pada

mesin induksi dalam rentang waktu 1 menit.

C. Analisa Sistem

Analisa sistem dilakukan untuk mendapatkan gambaran secara lengkap mengenai permasalahan dalam sistem diagnosis dan mencari kebutuhan sistem secara lengkap dengan harapan sistem yang dihasilkan akan dapat menghasilkan keakuratan perhitungan.

Sistem ini dibuat menggunakan metode klasifikasi support vector machine dengan menggunakan pendekatan one-against-one dan one-against-all yang diuji menggunakan 3 macam kernel untuk meningkatkan akurasi hasil klasifikasi. Data yang akan diolah diperoleh dari data getaran bantalan gelinding yang didapat dengan cara memasang transducer pada bantalan gelinding dan mengambil data getaran nya dengan interval waktu tertentu.

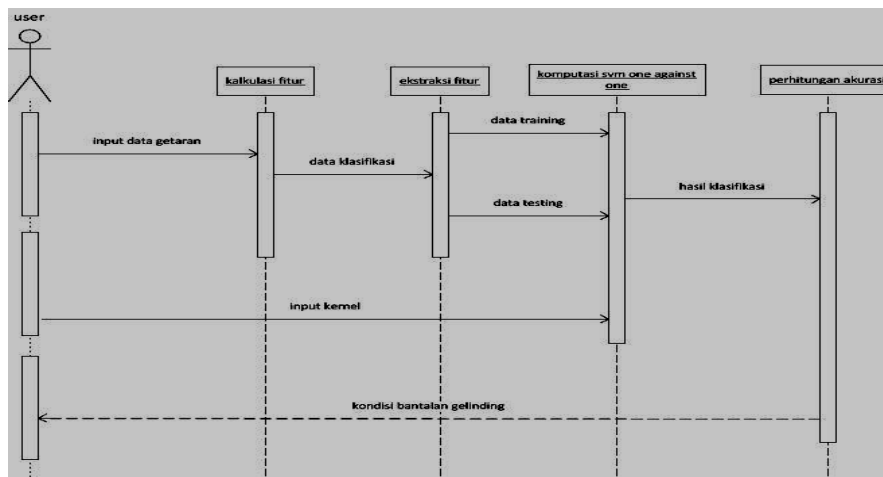


Gambar 5. Diagram uses case

uses case dimana aktor adalah seorang user yang menginputkan data berupa data getaran bantalan gelinding yang didapat dar transducer portabel dimana Untuk memperoleh data sinyal getaran, transducer diletakkan pada tiga titik yaitu secara vertikal, horizontal dan axial.

Selanjutnya data diolah dengan cara dikalkulasi dengan 21 fitur statistik ditambah dengan 4 fitur normalisasi yang dikenalkan oleh xinwen niu dkk. Hasil dari fitur tersebut kemudian di ekstraksi dengan menggunakan Principal componen analysis. Dari hasil ekstraksi tersebut

nanti nya didapat data latih dan data uji sebanyak 8 kelas dimana ke 8 kelas tersebut akan di masukkan kedalam model klasifikasi yang akan dibuat. Dalam penelitian kali ini model klasifikasi di buat dengan algoritma support vector machine menggunakan dua pendekatan yaitu pendekatan one against all dan one against one. Selain itu dalam penelitian kali ini juga di uji tiga macam kernel untuk mendapatkan hasil klasifikasi yang memiliki tingkat akurasi yang baik dalam hal ini prosentase mendekati 100%.



Gambar 6 Diagram sequence komputasi svm dengan pendekatan one against one & one against all

Dalam diagram pada Gambar 6 sequence ini user memiliki empat buah aktivitas yaitu input data getaran dimana data getaran akan di kalkulasi dengan fitur statistik yang menghasilkan 21 fitur. Hasil kalkulasi fitur tersebut kemudian ditambah


dengan fitur normalisasi dari xin wen niu dkk. Sehingga total fitur yang digunakan berjumlah 25 fitur. Fitur tersebut kemudian di ekstraksi menggunakan pendekatan principal component analisys untuk membuang data data yang saling berkorelasi

sehingga data yang didapat tidak terlalu besar. Data hasil ekstraksi tersebut akhirnya dibagi menjadi dua macam data yaitu data training untuk melatih model dan data testing untuk mengetes hasil klasifikasi.

Hasil dan Pembahasan

Metode pengumpulan data yang digunakan dalam penelitian ini adalah


metode pengumpulan data periodik dimana pengukuran getaran pada bantalan gelinding diukur menggunakan sistem portabel. Untuk memperoleh data sinyal getaran transducer diletakkan pada tiga titik yaitu secara vertikal, horizontal dan axial.



Gambar 7 letak transducer secara horizontal, vertikal dan axial

Besaran yang diukur adalah amplitudo getaran berbanding dengan waktu. data sampel yang diambil adalah

16,384 data yang diambil selama 2.133 detik dengan frekwensi sebesar 5KHz



Gambar 8 Amplitudo getaran bantalan gelinding

A. Kalkulasi Fitur

Dalam kalkulasi fitur ini digunakan 25 fitur yang terdiri dari 10 fitur time domain yang terdiri dari mean, rms, shape factor, skewness, kurtosis, crest factor, entropy error, entropy estimation, histogram lower dan histogram upper, 3 fitur frekuensi domain yaitu rms frequency,

frequency center and root variance frequency 8 fitur auto-regresion dan 4 fitur normalisasi yang di kenalkan oleh niu dkk.

Rumus dari normalisasi momen statistik tersebut adalah sebagai berikut :

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

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

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

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

Dari Ke 25 fitur tersebut, masing masing fitur terdiri dari 160 data yang terbagi ke dalam 8 kelas. Dimana masing masing kelas terdiri dari 20 data


Tabel 2. Nama kelas kerusakan

Nama Kelas	Keterangan
Angular Misalignment	terjadiketikapusatsumbuputardarikeduaporostidaksejajar, dimanaketidaklurusankeduaporossalingmenyudut.
Bowed Rotor Shaft	Terdapatbagian yang terdefleksi (melengkung) akibatbeban yang tidakmerata, sehinggaterjadilengkunganpada rotor
Broken Rotor Bar	Kerusakanpada rotor dimulaidaritingginyaresistensi yang menimbulkantingginyatemperatur yang berkembangmenjadiretakataulubangkecilpadabatang rotor
Faulty Bearing(outr ace)	Terjadikerusakanpadabagianterluarbantalangelinding
Rotor Unbalanced	Ketidakseimbanganadalahmasalah yang umumnyaterjadiketikasumbuutamainersiatidakbertepatan dengan sumbu geometris.
Normal Motor	Salah satukelasdimana data diambilpadasaat motor dalamkeadaan normal (tanpakerusakan).
Parallel Misalignment	<i>Parallel misalignment</i> , Sumbukeduaporostidakmenyatutetapisejajar
Phase Unbalanced	<i>Phase unbalanced</i> adalahposisitidakseimbangpadabagian yang berputar yang secaralangsungberhubunganpadasebuah fixed point.

B. Ekstraksi Fitur

Pada Prinsipnya ekstraksi fitur digunakan untuk merubah atau memetakan data dari dimensi yang lebih besar, ke dimensi yang lebih

kecil dengan menghilangkan data yang mirip atau berkorelasi. Model ekstraksi fitur yang digunakan adalah principal component yang menggunakan eigenvalue.



Gambar 9 Eigenvalue dari 25 fitur

Fitur pertama memiliki eigenvalue yang relative lebih besar dari yang lain. Dari kelima fitur yang masing-masing terdiri dari 160 data yang terbagi kedalam 8 kelas dimana masing masing kelas terdiri dari 20 data. Data tersebut akan dipecah menjadi 16 data training dan 4 data testing


C. Klasifikasi dan Pelatihan

Pada penelitian ini penulis menggunakan tiga kernel sebagai fungsi dasar Support Vector Machine yaitu kernel RBF, linear dan polinomial dimana kernel RBF memiliki 2 parameter yaitu C dan γ . Untuk mendapatkan nilai C dan γ yang optimal maka digunakan evalsvm

dengan 5 - fold cross validation untuk mendapatkan nilai kesalahan terkecil. Untuk nilai C akan diambil antara {1,2,4,8,16,32,64,128} dan untuk nilai γ akan diambil nilai antara {0.125, 0.25,0.5,1,2,4,8} dimana akan dihasilkan 56 model pemasangan nilai C dan nilai γ

Sedangkan untuk kernel polynomial ada sebuah nilai d yang akan diambil dengan nilai {2,3,4}

1. One against all dengan kernel linear Didapat model yang terbaik adalah model dengan nilai C adalah 32 dan nilai γ adalah 1. Dengan cross-validation error sebesar 0.1712 dan testing error (ans) sebesar 0.0625 dan training error sebesar 0.1154




Gambar 10. hasil klasifikasi oasvm dengan kernel linear

2. One Against all dengan kernel rbf

model dengan nilai C adalah 16 dan nilai γ adalah 0.125. Dengan cross-validation error sebesar 0.0551 dan

testing error (ans) sebesar 0.0938 dan data training error sebesar 0.0385 dan berikut ini adalah hasil plotting dari model diatas

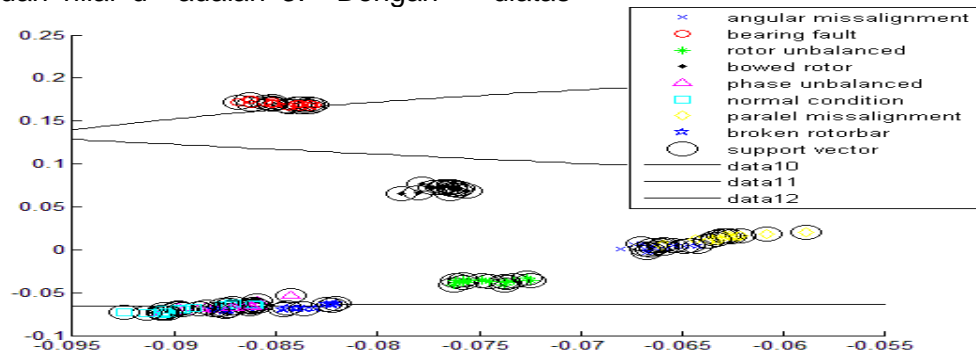


Gambar 11. hasil klasifikasi oasvm dengan kernel Rbf

3. One against all dengan kernel polinomial

Model yang terbaik yang didapat adalah model dengan nilai C adalah 64 dan nilai d adalah 3. Dengan

cross-validation error sebesar 0.1628 dan testing error (ans) sebesar 0.1875 dan nilai training error 0.1442 berikut ini adalah hasil plotting dari model diatas




Gambar 12. Hasil plotting model optimal dari oasvm kernel polynomial

4. One against one dengan kernel linear

Model yang terbaik yang didapat adalah model dengan nilai C adalah 64 dan nilai γ adalah 1. Dengan

cross-validation error sebesar 0.1013 dan testing error (ans) sebesar 1 dan training error sebesar 0.0673 berikut ini adalah hasil plotting dari model diatas




Gambar 13. Hasil plotting model optimal dari oasvm kernel linear

5. One against one dengan kernel Rbf

Model yang terbaik yang didapat adalah model dengan nilai C adalah 16 dan nilai γ adalah 0.25. Dengan cross-validation error sebesar 0.0673


dan testing error (ans) sebesar 1 dan training error sebesar 0.0673 berikut ini adalah hasil plotting dari model diatas



Gambar 14. Hasil plotting model optimal dari oasvm kernel rbf

6. *One against one* dengan kernel polynomial
 Model yang terbaik yang didapat adalah model dengan nilai C adalah 64 dan nilai d adalah 2. Dengan

cross-validation error sebesar 0.3462 dan *testing error* (ans) sebesar 0.9375 dan *training error* sebesar 0.3462 berikut ini adalah hasil plotting dari model diatas



. Gambar 15. Hasilploting model optimal dari oasvm kernel polynomial

Dari hasil penelitian kedua model klasifikasi multi kelas *one against all* (oasvm) dan *one against one* (oaosvm) didapat hasil sebagai berikut.

Table 3 Tabel Hasil Klasifikasi metode *one against all* dan *One Against one* dengan 3 kernel

Kernel	Strategi multikelas	data		Akurasi klasifikasi (%)		Banyaknya Support vector	Cross validation error
		training	testing	training	testing		
RBF (C, γ)	One vs all (16, 0.125)	128	32	99,97	99,71	61	0,0551
	One vs one (64, 0.25)	128	32	99,95	96,88	54	0.0625
Polynomial (C,d, γ)	One vs all (64,3,1)	128	32	99,89	99,42	104	0,1628
	One vs one (128,2,1)	128	32	99,73	97,10	97	0.3756
Linear (C)	One vs all (32)	128	32	99,91	99,97	82	0.1712
	One vs one (64)	128	32	99,95	99,88	65	0,1013

Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, maka dapat diambil kesimpulan sebagai berikut :

1. Hasil pembahasan menunjukkan bahwa metode Support Vector Machine dengan menggunakan pendekatan *one-against-all* dan *one-against-one* cukup bagus digunakan untuk mendiagnosis kerusakan bantalan gelinding dari suatu mesin industri. dengan mengaplikasikan 3 macam kernel, tingkat akurasi dalam memisahkan jenis kerusakan didapat masih diatas 95%. Sedangkan pendekatan yang terbaik diperoleh dari pendekatan *one-against all* dengan tingkat akurasi untuk

memisahkan jenis kerusakan diatas 99%

2. Hasil diagnosis dalam penelitian ini dapat digunakan untuk membantu dalam pengambilan keputusan untuk mengambil tindakan perbaikan atau untuk mendukung hasil dari prognosis.

Daftar Pustaka

- Cristianini, N.andShawe-Taylor, J., 2000, *An Introduction to Support Vector Machines*.Cambridge University Press.
 Dergibson Siagian & Sugiarto., 2002, *Metode Statistika untuk Bisnis dan*

- Ekonomi*, PT Gramedia Pustaka Utama, Jakarta.
- Han, Jiawei. Kamber, Micheline., 2006 *Data Mining: Concepts and Techniques, 2nd ed.* Morgan Kaufmann Publishers.
- Morariu, D., 2005, *Data Mining For unstructured Data*. MSc thesis, Engineering Faculty Computer science department university of sibi. Sibiu.
- Mukkamala, S. et al., 2003, *Feature Selection for Intrusion Detection using Neural Networks and Support Vector Machines*. MIT
- Niu, Xinwen., Zhu, Limin., dan Ding, Han., 2005, *New Statistical Moments for Detection of Defects in Rolling Element Bearings, Int J Adv Manuf Technol*, 1268-1274
- Prasetyo, Eko., 2012, *Data Mining : Konsep dan Aplikasi Menggunakan Matlab*, CV Andi Offset, Yogyakarta.
- Sembiring, K., 2007, *Penerapan Teknik Support Vector Machine untuk Pendeteksian Intrusi pada Jaringan*. ST skripsi, S1 Teknik Informatika, Institut Teknologi Bandung.
- Vapnik, V., 1995, *The Nature of Statistical Learning Theory*. Springer Verlag, 1995.
- Vachtsevanos, G. et al., 2006, *Intelligent Fault Diagnosis And Prognosis For Engineering Systems*. Jhon Wiley & Sons, Inc, New Jersey.
- Widodo, A., 2009, *Aplication Of Inteligent System For Machine Fault Diagnosis And Prognosis.*, Universitas Diponegoro Publishers, Semarang.
- Widodo, A., 2007, *Support Vector Machine for Machine Fault Diagnosis and Prognosis*. Dr. Disertation, Department of Mechanical Engineering, Pukyong National University.