

## Deteksi Kerusakan *Bearing* Menggunakan Komponen Utama Kernel

Allyaa Putri Asti, Sutawanir Darwis\*

*Prodi Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Bandung, Indonesia.*

### ARTICLE INFO

#### Article history :

Received : 10/2/2023

Revised : 27/6/2023

Published : 13/7/2023



Creative Commons Attribution-  
NonCommercial-ShareAlike 4.0  
International License.

Volume : 3

No. : 1

Halaman : 19 - 26

Terbitan : **Juli 2023**

### ABSTRAK

Berbagai faktor dapat menyebabkan kerusakan bearing, hal ini merupakan masalah utama karena dapat menyebabkan kerugian cukup besar dan mempengaruhi jadwal produksi. Metode digunakan dalam penelitian Hotelling T2 melalui komponen utama kernel. Komponen utama kernel digunakan untuk mengkonstruksi statistik Hotelling T2 sehingga diperoleh nilai statistik T2 untuk deteksi kerusakan bearing. Tujuan penelitian adalah menerapkan komponen utama kernel sebagai statistik untuk menggunakan Hotelling T2 bearing normal dan bearing rusak. Data sekunder NASA Bearing Dataset berisikan data bearing normal serta data bearing rusak. Proses deteksi bearing melalui komponen utama kernel dibagi menjadi Data Training sebanyak 1153 data sedangkan Data testing sebanyak 323 data. Berdasarkan hasil penelitian, 8 fitur dijadikan sebagai input komponen utama kernel, direduksi menjadi enam komponen utama kernel. Menggunakan Data Training diperoleh nilai eigen sebagai input Hotelling T2, Data testing digunakan untuk mendeteksi kondisi bearing. Bearing terdeteksi rusak ketika statistik  $T2 > 12.6939$ . Dengan taraf signifikansi 5 %, didapatkan sebanyak 294 data pengamatan dari 323 terdeteksi merupakan bearing rusak sedangkan sisanya 29 data pengamatan terdeteksi merupakan bearing normal. Setelah dilakukan penelitian metode komponen utama kernel layak digunakan untuk mendeteksi kerusakan bearing.

**Kata Kunci** : Deteksi Kerusakan Bearing; Komponen Utama Kernel; Vibrasi Bearing.

### ABSTRACT

Various factors can cause bearing damage, this is a major problem because it can cause substantial losses and affect production schedules. The method used in this paper is Hotelling T2 through Kernel Principal Component Analysis (KPCA). The principal component of kernel used to construct Hotelling T2 statistics in order to obtain T2 statistical values for detection bearing damage. The purpose of this paper is to apply KPCA as a statistic to use normal and damaged bearing. Data from NASA Bearing Dataset that contains normal bearing and damage bearing. Data divided into 1153 data for training and 323 data for testing. In this paper, 8 features are used as input for KPCA, reduced to 6 kernel principal component. Training data can obtained eigenvalue as input Hotelling T2, testing is used to detect bearings condition. Bearings are detected to damaged when  $T2 > 12.6939$  with a significance level of 5%, from 323 training data 294 observations detected as damaged bearings and 29 observations detected as normal bearings. After conducting research, KPCA method can use to detect bearing damage.

**Keywords** : Bearing Damage Detection; Kernel Principal Component Analysis; Bearing Vibration.

© 2023 Jurnal Riset Ekonomi Syariah Unisba Press. All rights reserved.

## A. Pendahuluan

*Bearing* merupakan bagian penting pada mesin berputar karena mempengaruhi presisi kinerja, masa pakai keseluruhan peralatan dan keandalan operasi. Namun, tidak peduli seberapa baik mereka dirancang karena proses penuaan alami dan berbagai faktor lain dapat menyebabkan kerusakan pada *bearing*. Kerusakan *bearing* dapat menyebabkan kebisingan, suhu kerja yang meningkat serta kerusakan pada bagian mesin dikarenakan bunga api yang timbul. Hal tersebut merupakan masalah utama karena dapat menyebabkan kerugian yang cukup besar terhadap biaya dan jadwal produksi. Perlu dilakukan diagnosis kerusakan *bearing* untuk mencegah kerusakan serius pada mesin [1].

Maka untuk mendeteksi kerusakan *bearing* ini dapat dilakukan dengan cara melakukan pemantauan kondisi *bearing* melalui data vibrasi *bearing*, selanjutnya data vibrasi *bearing* akan di ekstrasi menjadi fitur statistik [2]. Fitur statistik digunakan untuk mendapatkan informasi utama mengenai sinyal vibrasi *bearing*. Fitur umum yang sering digunakan terdiri dari rata – rata, standar deviasi, *Root Mean Square (RMS)*, *skewness*, *peak to peak* dan kurtosis. Analisis Komponen Utama Kernel adalah perluasan PCA nonlinier yang terdiri dari pengamatan terhadap struktur fitur dimensi yang lebih besar (berpotensi tak terbatas) menggunakan array yang tidak linier dan kemudian mengukur titik dalam ruang fitur [3].

Untuk memperluas teknik dalam menangani struktur data nonlinier, pengembangan dari analisis komponen utama telah banyak dilakukan. Salah satu pengembangan dari analisis komponen utama dengan menggunakan fungsi kernel. Komponen utama kernel pertama kali dikembangkan oleh SchölkopfSch & Smola Klaus-Robert [4] menyatakan bahwa komponen utama kernel telah berhasil digunakan dalam pemantauan proses dan aplikasi diagnosis kesalahan dalam penelitian ini analisis komponen utama diterapkan pada kasus nonlinier dengan memetakan sampel input secara nonlinier ke ruang fitur dimensi yang lebih tinggi sebelum melakukan analisis komponen utama. Menurut Lee et al. [5] menyatakan bahwa komponen utama kernel telah berhasil digunakan dalam pemantauan proses dan aplikasi diagnosis kesalahan. Menurut Wang & Deng [6] Komponen utama kernel memiliki kemampuan untuk mendeteksi kerusakan lebih efektif jika dibandingkan dengan komponen utama.

Berdasarkan uraian diatas, penelitian skripsi ini membahas mengenai deteksi kerusakan *bearing* dengan menggunakan komponen utama kernel. Fitur statistik dari data vibrasi *bearing* yang diperoleh dari NASA menjadi obyek pada penelitian skripsi ini. Data vibrasi *bearing* akan diekstraksi menjadi 8 fitur statistik dilanjutkan dengan mencari matriks ruang ciri dengan menggunakan fungsi kernel. Vektor ciri pada *Data Training* serta skor komponen dari *Data testing* selanjutnya diinputkan pada *Hotelling T2* kemudian akan dibuat plot *Hotelling T2* untuk mendeteksi *bearing* normal atau *bearing* rusak.

Berdasarkan dari uraian diatas, maka diperoleh identifikasi masalah dalam skripsi ini yaitu, bagaimana deteksi kerusakan *bearing* menggunakan komponen utama kernel. Selanjutnya, tujuan dalam penelitian ini yaitu memperkirakan kerusakan *bearing* dengan menggunakan metode komponen utama kernel.

## B. Metode Penelitian

### Komponen Utama Kernel

Menurut SchölkopfSch [4] mengemukakan bahwa komponen utama kernel memungkinkan untuk menggeneralisasi komponen utama dengan tujuan untuk mengurangi dimensi nonlinear. Gagasan utama dari algoritma komponen utama kernel adalah melakukan transformasi nonlinier menggunakan fungsi non-linier  $\Phi$  dengan memetakan vektor input  $x_i$  ke ruang fitur  $F$  dengan dimensi tinggi, lalu menghitung analisis komponen utama linier di  $\Phi(x_i)$  yang berdimensi lebih tinggi dari  $m$ . Fungsi pemetaannya adalah sebagai berikut:

$$\Phi: x_i \rightarrow \Phi(x_i) \in F \quad (1)$$

Komponen utama kernel diterapkan pada dua data: *Data Training* dan *Data testing*.

### *Data Training*

*Data training* ini bertujuan untuk mendapatkan matriks **unit**, vektor eigen dan nilai limit  $T^2$  *Hotelling* yang nantinya akan digunakan pada *Data testing* dan perhitungan  $T^2$  *Hotelling*. Pertama Diketahui sebuah matriks  $X$  berukuran  $n \times p$  [7]

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix} \tag{2}$$

Kemudian melakukan pembakuan data, pembakuan data disini perlu dilakukan agar data yang dimiliki memiliki skala pengukuran yang sama [8]. Pembakuan data berasal dari perhitungan data dikurangi rata – rata kemudian dibagi dengan simpangan baku. Nantinya data baru yang sudah dibakukan akan berbentuk matriks **X** dengan ukuran  $n \times p$

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix} \tag{3}$$

Selanjutnya yaitu kekuatan metode kernel, secara eksplisit tidak harus untuk menghitung  $\Phi(x_i)$ . Terdapat beberapa jenis kernel yang sering digunakan, seperti kernel polynomial, kernel Gaussian, dan kernel RBF. Namun, pada penelitian ini menggunakan kernel Gaussian dikarenakan kernel Gaussian terbukti memberikan hasil kernel yang baik dibandingkan fungsi kernel yang lain dengan  $\gamma = 0.01$  pada persamaan [8] :

$$k(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \tag{4}$$

dengan :

$$k(x_i, x_j) : x \times x \rightarrow R \text{ dimana } i, j = 1, 2, 3, \dots, n.$$

$$\|x_i - x_j\|^2 = \text{jarak euclidean antara } x$$

Setelah itu Membuat matriks kernel **K** dengan menggunakan fungsi kernel Gaussian, dimana matriks kernel **K** berukuran  $n \times n$

$$K = \begin{bmatrix} k(x_1, x_1) & k(x_1, x_2) & \dots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \dots & k(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ k(x_n, x_1) & k(x_n, x_2) & \dots & k(x_n, x_n) \end{bmatrix} \tag{5}$$

Selanjutnya melakukan sentralisasi kernel matriks **K** untuk mendapatkan matriks **K\_C** berukuran  $n \times n$ . Sentralisasi kernel bertujuan untuk membakukan data pada ruang *feature* walaupun sebelumnya data sudah di bakukan namun pada ruang fitur perlu data baru sehingga dilakukan sentralisasi kernel menggunakan persamaan [4]:

$$K_C = K - UK - KU + UKU \tag{6}$$

dengan **U** berukuran  $n \times n$

$$U = \frac{1}{n} \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & 1 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 1 \end{bmatrix} \tag{7}$$

Setelah mendapat nilai U, langkah selanjutnya yaitu menghitung **nilai eigen** dan **eigen vektor** dari matriks **K\_C**

$$n\lambda\alpha = K_C\alpha. \tag{8}$$

Selanjutnya yaitu pengambilan nilai komponen. Pengambilan banyak komponen utama ditentukan melalui beberapa cara, namun tidak terdapat aturan khusus karena pada dasarnya penentuan banyaknya komponen utama tergantung pada kebutuhan penelitian [9]. Pada penelitian ini pengambilan nilai komponen utama berdasarkan proporsi kumulatif varians yang dapat dijelaskan oleh komponen utama. Banyaknya komponen utama yang diambil yaitu mencakup paling sedikit 80% varians pada data atau dapat dikatakan

paling sedikit dapat menangkap 80% keragaman data. Setelah didapatkan banyaknya komponen utama, selanjutnya menghitung komponen utama kernel

$$\mathbf{Z} = \mathbf{K\_CV} \tag{9}$$

Dimana,

V = Vektor Eigen ; K\_C = Sentralisasi Kernel Matriks

**Data Testing**

Data testing bertujuan untuk mendapatkan nilai komponen utama untuk selanjutnya diinputkan pada Hotelling T<sup>2</sup> untuk mengecek menguji apakah bearing tersebut termasuk bearing rusak ataukah bearing normal. Misal diketahui sebuah matriks X<sub>t</sub> berukuran m×p

$$\mathbf{X}_t = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mp} \end{bmatrix} \tag{10}$$

Langkah pertama yaitu melakukan pembakuan data matriks X<sub>t</sub> sehingga didapatkan matriks **X<sub>t</sub>** dengan ukuran m×p

$$\mathbf{X}_t = \begin{bmatrix} \mathbf{x}_{11} & \mathbf{x}_{12} & \dots & \mathbf{x}_{1p} \\ \mathbf{x}_{21} & \mathbf{x}_{22} & \dots & \mathbf{x}_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_1 & \mathbf{x}_{m2} & \dots & \mathbf{x}_{mp} \end{bmatrix} \tag{11}$$

Setelah itu menghitung Kernel Gaussian. Terdapat beberapa jenis kernel yang sering digunakan, seperti kernel polynomial, kernel Gaussian, dan kernel RBF. Namun, pada penelitian ini menggunakan kernel Gaussian dengan  $\gamma = 0.01$  pada persamaan :

$$k_t(x_{ti}, x_j) = \exp\left(-\gamma \|x_{ti} - x_j\|^2\right)$$

dengan :

$$k_t(x_{ti}, x_j) \text{ dimana } i \neq j, i = 1,2,3,\dots,m \text{ dan } j = 1,2,3,\dots,n \tag{12}$$

$\|x_{ti} - x_j\|^2 = \text{jarak euclidean antara } x \text{ testing dan } x \text{ training}$

Setelah itu membuat matriks kernel **K<sub>t</sub>** dengan menggunakan fungsi kernel gaussian, dimana matriks kernel **K<sub>t</sub>** berukuran m×n

$$\mathbf{K}_t = \begin{bmatrix} k_t(x_{t1}, x_1) & k_t(x_{t1}, x_2) & \dots & k_t(x_{t1}, x_n) \\ k_t(x_{t2}, x_1) & k_t(x_{t2}, x_2) & \dots & k_t(x_{t2}, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ k_t(x_{tm}, x_1) & k_t(x_{tm}, x_2) & \dots & k_t(x_{tm}, x_n) \end{bmatrix} \tag{13}$$

Selanjutnya melakukan sentralisasi kernel matriks **K<sub>t</sub>** untuk mendapatkan matriks **K<sub>t-C</sub>**, sentralisasi kernel sendiri bertujuan untuk menormalkan data pada ruang feature menggunakan persamaan :

$$\mathbf{K}_{t-C} = \mathbf{K}_t - \mathbf{u}_1 \mathbf{K} - \mathbf{K}_t \mathbf{U} + \mathbf{u}_1 \mathbf{K} \mathbf{U} \tag{14}$$

dengan **u<sub>1</sub>** berukuran m×n, maka:

$$\mathbf{u}_1 = \frac{1}{n} \begin{bmatrix} 1 & 1 & \dots & 1 \\ 1 & 1 & \dots & 1 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & \dots & 1 \end{bmatrix} \tag{15}$$

Kemudian menghitung nilai komponen utama untuk data testing dengan menggunakan didapatkan nilai komponen utama dari nilai eigen :

$$\mathbf{Z}_t = \mathbf{K}_{t-C} \mathbf{CV} \tag{16}$$

**Hotelling  $T^2$  Melalui Komponen Utama Kernel**

Hotelling  $T^2$  dapat digunakan untuk mendeteksi *bearing* rusak pada data proses multivariat. Hipotesis Pengujian yang digunakan yaitu:  $H_0$ : Tidak terjadi kerusakan pada *bearing*, dan untuk  $H_1$ : Terjadi kerusakan pada *bearing* [10]. Sedangkan untuk statistik uji untuk tiap-tiap pengamatan, yaitu:

$$T_i^2 = Z_i^T \Lambda^{-1} Z_i \tag{17}$$

dimana:

$T_i^2$  = statistik uji setiap pengamatan

$Z_i$  = skor komponen utama kernel

$$\Lambda^{-1} = \begin{bmatrix} \frac{1}{\lambda_1} & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \frac{1}{\lambda_2} & \ddots & \vdots \\ \vdots & \vdots & \dots & \frac{1}{\lambda_a} \\ \mathbf{0} & \mathbf{0} & \dots & \mathbf{0} \end{bmatrix}$$


Kriteria Uji yang digunakan adalah Tolak  $H_0$  jika  $T^2 > T_\alpha^2$ , dimana  $T_\alpha^2 = \frac{a(n-1)}{n-a} F_\alpha(a, n - a)$ ,  $n$  = banyak sampel, dan  $a$  = banyaknya komponen utama kernel. Setelah mendapatkan nilai  $T^2$ , selanjutnya visualisasi berupa diagram kendali  $T^2$ . Diagram kendali Hotelling  $T^2$  adalah salah satu jenis diagram kendali variabel yang digunakan pada data yang lebih dari satu variabel yang saling berkorelasi dan digunakan untuk mengontrol vektor mean dalam proses multivariat [11]. Untuk Penentuan batas-batas kendali Hotelling  $T^2$  yaitu BKA =  $T_\alpha^2 = \frac{a(n-1)}{n-a} (a, n - a)$  dan BKB = 0. Dimana  $n$  merupakan banyak sampel,  $a$  merupakan banyak komponen utama kernel,  $F_\alpha(a, n - a)$  nilai Tabel F dengan  $\alpha = 0.05$ . Apabila  $T_i^2 > BKA$  maka pengamatan ke- $i$  *out of control*.

**Data**

Data yang digunakan yaitu data sekunder dari uji *bearing* yang menghasilkan data kerusakan. Data tersebut dapat diunduh dari Prognostics Center of Excellence (PcoE) melalui penyimpanan data prognostik yang disumbangkan oleh Intelligent Maintenance System (IMS), University of Cincinnati. Data pada *bearing* terdiri dari empat *bearing* yang dipasang pada satu poros. Kecepatan rotasi poros dijaga konstan pada 2000 rpm dan beban 26690N ditempatkan pada poros dan *bearing* dengan mekanisme pegas. 4 bantalan *bearing* yang digunakan adalah Rexnord ZA-115 dua baris *bearing* yang memiliki 16 rol disetiap baris, diameter *pitch* 71,5 mm, diameter rol 8,4 mm dan sudut kontak meruncing 15,17o. Pengujian ini melibatkan 1 data set vibrasi *bearing* dengan kondisi yang berbeda. Data set diperoleh pada waktu  $t = 2003.10.22.12.06.24$  sampai dengan  $t=2003.11.25.23.39.56$ . Dengan variabel penelitian yaitu  $X1 = \text{Maximum}$ ,  $X2 = \text{Minimum}$ ,  $X3 = \text{Mean}$ ,  $X4 = \text{standar deviasi}$ .,  $X5 = \text{RMS}$ ,  $X6 = \text{skewness}$ ,  $X7 = \text{kurtosis}$ .  $X8 = \text{peak-value}$ .

**C. Hasil dan Pembahasan**

**Jumlah Komponen Utama**



**Gambar 1.** Pengambilan Jumlah Komponen Utama

Pada Gambar 1 dapat dijelaskan bahwa jumlah komponen utama yang akan dipilih sebanyak enam komponen utama. Enam komponen utama yang diambil mencakup paling sedikit 96.5 % varians pada data atau dapat dikatakan paling sedikit dapat menangkap 96.5 % keragaman data.

**Komponen Utama Data Training**


Berikut ini adalah nilai komponen utama untuk data training sebanyak 1153 data dengan 6 komponen utama. Hasil pengujian dapat dijelaskan pada tabel 1.

**Tabel 1.** Hasil Pengujian

	1	2	3	4	5	6
1	-0.00151	0.073222	0.083687	0.060846	0.09738	-0.01007
2	-0.02002	0.165132	0.071801	0.156302	-0.05525	-0.02984
3	0.021394	-0.11116	0.067877	0.061076	-0.07418	-0.0023
4	-0.15862	-0.06226	0.086843	-0.00909	-0.05734	-0.02766
5	0.150479	0.163228	0.140629	0.080082	-0.0169	0.011423
⋮	⋮	⋮	⋮	⋮	⋮	⋮
1149	0.032887	0.195309	0.13623	0.139077	-0.06364	-0.0008
1150	-0.01677	-0.08447	0.176687	0.164143	-0.03683	0.0081
1151	0.142276	-0.04043	0.12958	0.17747	-0.05246	-0.00307
1152	-0.02802	-0.00841	0.066089	0.240572	0.080118	-0.0245
1153	0.195207	0.079378	0.189494	0.151068	-0.04781	0.007265

**Hotelling T<sup>2</sup> Data Training**

Berikut adalah penelitian Hotelling T<sup>2</sup> Data Training dimana jumlah Data Training yang diinputkan adalah 1153. Setelah melalui serangkaian perhitungan menggunakan komponen utama kernel, hasil pengujian dijelaskan pada tabel 2.



**Gambar 2.** Diagram Hotelling T<sup>2</sup> Data Training

**Tabel 2.** Hasil Pengujian

No	T <sub>i</sub> <sup>2</sup>	T <sub>α</sub> <sup>2</sup>	Keputusan signifikansi
1	4.0223	< 12.6939	H0 Tidak Ditolak, In Control
2	7.9167	< 12.6939	H0 Tidak Ditolak, In Control
3	3.0199	< 12.6939	H0 Tidak Ditolak, In Control
⋮	⋮	⋮	⋮
1151	7.542693	< 12.6939	H0 Tidak Ditolak, In Control
1152	10.76262	< 12.6939	H0 Tidak Ditolak, In Control
1153	9.547431	< 12.6939	H0 Tidak Ditolak, In Control

Nilai *Hotelling*  $T^2$  akan dibandingkan oleh nilai  $T^2_\alpha$  agar dapat mengambil keputusan signifikansi dengan nilai alpha ( $\alpha$ ) yang dipakai sebesar 0.05. Berdasarkan Tabel 2 dapat disimpulkan bahwa terdapat pengamatan hipotesis nol ( $H_0$ ) tidak ditolak sebab  $T^2 < T^2_\alpha$  artinya semua pengamatan tidak terjadi kerusakan atau dapat dikatakan *bearing* dalam kondisi normal.

**Komponen Utama Data testing**


Berikut ini adalah nilai komponen utama untuk *Data Training* sebanyak 323 data dengan 6 komponen utama. Hasil pengujian dapat dijelaskan pada tabel 3.

**Tabel 3.** Hasil Pengujian

	1	2	3	4	5	6
1	0.20126	0.255301	-0.02823	0.420956	0.08193	-0.09124
2	-0.06505	0.201072	-0.1119	0.454225	-0.00901	-0.07699
3	-0.09407	0.353902	0.235172	0.306826	-0.13964	-0.06456
4	-0.01203	-0.03309	0.218098	0.367154	-0.05728	-0.03437
5	0.062336	0.444792	0.150994	0.215799	-0.03481	-0.08587
⋮	⋮	⋮	⋮	⋮	⋮	⋮
319	0.013993	0.01015	-0.00861	-0.0198	-0.02037	-0.35111
320	0.013143	0.009788	-0.00941	-0.02171	-0.01993	-0.35098
321	0.013141	0.009786	-0.00941	-0.02172	-0.01993	-0.35098
322	0.013183	0.009791	-0.00938	-0.02162	-0.01996	-0.35099
323	0.013141	0.009786	-0.00941	-0.02172	-0.01993	-0.35098

**Hotelling  $T^2$  Data testing**

Berikut adalah penelitian *Hotelling  $T^2$  data testing* dimana jumlah *data testing* yang diinputkan adalah 323. Setelah melalui serangkaian perhitungan menggunakan komponen utama kernel, hasil pengujian dijelaskan pada tabel 4.



**Gambar 3.** Diagram *Hotelling  $T^2$  Data Testing*

**Tabel 4.** Hasil Pengujian

No	$T^2_i$		$T^2_\alpha$	Keputusan signifikansi
1	48.3514	>	12.6939	$H_0$ Ditolak, Out of Control
2	43.22079831	>	12.6939	$H_0$ Ditolak, Out of Control
3	39.18791	>	12.6939	$H_0$ Ditolak, Out of Control
⋮	⋮	⋮	⋮	⋮
321	271.5416503	>	12.6939	$H_0$ Ditolak, Out of Control
322	271.5551802	>	12.6939	$H_0$ Ditolak, Out of Control
323	271.5415679	>	12.6939	$H_0$ Ditolak, Out of Control

Berdasarkan Tabel 4 dapat disimpulkan bahwa terdapat 294 pengamatan hipotesis nol ( $H_0$ ) ditolak sebab nilai  $T^2 > T^2_\alpha$ , artinya sebanyak 294 pengamatan terjadi kerusakan atau dapat dikatakan *bearing* terdeteksi rusak. Sedangkan 29 pengamatan hipotesis nol ( $H_0$ ) tidak ditolak sebab nilai  $T^2 < T^2_\alpha$ , artinya sebanyak 29 pengamatan tidak terjadi kerusakan atau dapat dikatakan *bearing* dalam kondisi normal, terdeteksi tidak rusak.

#### D. Kesimpulan

Dari hasil perhitungan Penelitian deteksi kerusakan *bearing* menggunakan reduksi komponen utama kernel menunjukkan bahwa statistik *Hotelling* cukup akurat dalam mendeteksi kerusakan *bearing*. Prosedur uji *Hotelling* terdiri dua tahap: pembentukan diagram kendali *Hotelling* menggunakan *data training* dan untuk pengujian diagram *Hotelling* digunakan *data testing*.

#### Daftar Pustaka

- [1] M. Fathurrohman, R. G. Lulus Lambang H, and D. Djoko Susilo, "Diagnosa Kerusakan Bantalan Bola Menggunakan Metode Support Vector Machine," 2019.
- [2] M. Devega, "Diagnosis Kerusakan Bantalan Gelinding Menggunakan Metode Radial Basis Function Neural Network (RBFNN)," 2013.
- [3] H. Qian, Y. Liu, and P. Lv, "Kernel Principal Components Analysis for Early Identification of Gear Tooth crack," *IEEE*, 2006.
- [4] B. SchölkopfSch and A. M. Smola Klaus-Robert, *Communicated by Peter Dayan Nonlinear Component Analysis as a Kernel Eigenvalue Problem*. 1998.
- [5] J. M. Lee, C. K. Yoo, S. W. Choi, P. A. Vanrolleghem, and I. B. Lee, "Nonlinear process monitoring using kernel principal component analysis," *Chem Eng Sci*, vol. 59, no. 1, pp. 223–234, 2004, doi: 10.1016/j.ces.2003.09.012.
- [6] Y. Wang and F. Deng, "A sensor fault diagnosis method based on KPCA and contribution graph," *Vibroengineering PROCEDIA*, vol. 33, pp. 6–10, Oct. 2020, doi: 10.21595/vp.2020.21620.
- [7] R. Wilkinson, "Applied Multivariate Statistics: Hotelling's  $T^2$  distribution."
- [8] F. Shahzad, Z. Huang, and W. H. Memon, "Process Monitoring Using Kernel PCA and Kernel Density Estimation-Based SSGLR Method for Nonlinear Fault Detection," *Applied Sciences (Switzerland)*, vol. 12, no. 6, Mar. 2022, doi: 10.3390/app12062981.
- [9] Mas'ad, H. Yasin, and D. A. I. Maruddani, "Analisis Faktor-Faktor yang Mempengaruhi Persentase Penduduk Miskin di Jawa Tengah Dengan Metode Geographically Weighted Principal Components Analysis (GWPCA) Adaptive Bandwidth," *Jurnal Gaussian*, vol. 5, no. 3, pp. 487–496, 2016.
- [10] U. Unaijah and S. Darwis, "Prediksi Sisa Umur Bearing Menggunakan Distribusi Weibull," *Jurnal Riset Statistika*, pp. 73–81, Jul. 2022, doi: 10.29313/jrs.vi.909.
- [11] D. A. Awitasari, "Peta Kendali Multivariat Hotelling T2 Untuk Pengendalian Kualitas Nilai Mahasiswa Pada Empat Mata Kuliah Inti Di Jurusan Statistika Universitas Islam Indonesia," 2018.