

Sistem Identifikasi Kerusakan Bearing Berbasis Frekuensi Karakteristik Dan Klasifikasi Kondisi Gearset Pada Roll Konveyor Robo Arm Palletizer

Harris Fikri Satria Utama¹, Dwiky Fajri Syahbana^{*2}, Berlian Al Kindhi³

^{1,2,3} Departemen Teknik Elektro Otomasi, Fakultas Vokasi, Institut Teknologi Sepuluh Nopember, Surabaya
Email: ¹2040211009@student.its.ac.id, ²dwiky@its.ac.id, ³berlian@its.ac.id

^{*}Penulis Korespondensi

Abstrak

Bearing pada sistem konveyor memiliki peran penting dalam menjaga kelancaran operasional, terutama pada Robo Palletizer Fuji yang digunakan di perusahaan produsen pupuk. Penelitian ini bertujuan untuk merancang dan mengembangkan sistem klasifikasi kerusakan bearing dan gearset menggunakan metode *K-Nearest Neighbors (KNN)*. Parameter utama yang digunakan meliputi data getaran dan kecepatan rotasi (*RPM*). Sistem ini diimplementasikan dalam lingkungan industri dan dirancang untuk mengidentifikasi kondisi kerusakan komponen secara otomatis berdasarkan data real-time dari sensor. Klasifikasi kerusakan gearset dilakukan dengan metode KNN menggunakan parameter *RPM* motor dan *RPM* roll. Sementara itu, deteksi kerusakan bearing dilakukan dengan pendekatan berbasis rumus frekuensi karakteristik (*BPFO*, *BPFI*, *BSF*, dan *FTF*) yang dihitung dari data getaran. Sistem diuji menggunakan sekitar 6.500 data yang diperoleh selama kegiatan penelitian di perusahaan produsen pupuk dan dievaluasi berdasarkan akurasi klasifikasinya. Penelitian ini diharapkan dapat membantu proses identifikasi kerusakan komponen secara lebih cepat dan tepat serta mendukung penerapan teknologi Industri 4.0 di sektor manufaktur.

Kata kunci: Bearing, Gearset, Konveyor, K-Nearest Neighbors, Klasifikasi

Abstract

Bearings in conveyor systems play a crucial role in ensuring smooth operations, particularly in the Robo Palletizer Fuji used at the fertilizer manufacturing company. This research aims to design and develop a classification system for bearing and gearset damage using the *K-Nearest Neighbors (KNN)* algorithm. The system utilizes key parameters such as vibration data and rotational speed (*RPM*) to determine the condition of each component. The system is implemented in an industrial setting and is designed to automatically classify the condition of components based on real-time sensor data. Gearset damage classification is conducted using KNN with input features including motor and roll *RPM*, while bearing damage detection is performed through a formula-based approach using characteristic fault frequencies (*BPFO*, *BPFI*, *BSF*, and *FTF*) derived from vibration signals. Approximately 6,500 data samples were collected during a research at fertilizer manufacturing company and used to evaluate the accuracy of the classification system. The research is expected to assist in faster and more precise identification of component fault and support the adoption of Industry 4.0 technologies in the manufacturing sector.

Keywords: Bearing, Classification, Gearset, Conveyor, K-Nearest Neighbors.

I. PENDAHULUAN


Perusahaan produsen pupuk adalah salah satu perusahaan yang mengandalkan sistem pengemasan otomatis berbasis Robo Palletizer. Sistem ini mengandalkan roll konveyor untuk memindahkan karung pupuk ke jalur distribusi. Dalam praktiknya, terjadi kerusakan berulang pada komponen bearing dan gearset akibat kerja tanpa sistem pemantauan otomatis. Selama ini, inspeksi masih bersifat manual dan reaktif sehingga efisiensi perawatan menurun [1], [2], [3], [4], [5], [6].

Penelitian ini mengembangkan sistem identifikasi kerusakan bearing dan klasifikasi kondisi gearset berbasis data sensor. Sistem menggunakan sensor getaran ADXL335 dan sensor *RPM* E18-D80NK yang dipasang pada motor dan roll konveyor. Deteksi kerusakan bearing dilakukan dengan analisis frekuensi karakteristik seperti *BPFO*, *BPFI*, *BSF*, dan *FTF* menggunakan Fast Fourier Transform (FFT) [1], [2], [3], [5], [6], [7], sedangkan klasifikasi kondisi gearset dilakukan dengan metode *K-Nearest Neighbors (KNN)* berdasarkan perbedaan nilai *RPM* motor dan roll [8].

Tujuan dari penelitian ini adalah merancang sistem yang mampu mengklasifikasikan kondisi bearing dan gearset secara otomatis, serta memvisualisasikan hasilnya melalui antarmuka grafis. Dengan penerapan teknologi ini, diharapkan proses maintenance dapat dilakukan secara lebih efisien dan mendukung penerapan konsep Industri 4.0.

II. METODE PENELITIAN

Penelitian ini mengembangkan sistem monitoring kondisi bearing dan gearset pada roll konveyor Robo Arm Palletizer dengan pendekatan dua jalur: identifikasi kerusakan bearing berbasis frekuensi karakteristik, dan klasifikasi kondisi gearset menggunakan algoritma K-Nearest Neighbors (KNN). Sistem ini terdiri dari tiga komponen utama, yaitu akuisisi data, pemrosesan data, dan antarmuka hasil [1], [2].



Gambar 1. Diagram Blok


2.1 Objek Penelitian

Objek penelitian pada studi ini adalah bearing tipe UC205 dan gearset yang terpasang pada sistem roll konveyor Robo Arm Palletizer di PT Petrokimia Gresik. Kedua komponen ini dipilih karena merupakan bagian vital dalam mekanisme transmisi daya pada konveyor dan sering menjadi sumber utama permasalahan performa serta downtime di industri.



Gambar 2. Bearing UC205

Bearing UC205 berperan sebagai penyangga poros roll konveyor yang menerima beban dinamis secara terus-menerus. Kondisi bearing sangat berpengaruh terhadap kestabilan operasi sistem dan sering mengalami kerusakan akibat beban berulang serta lingkungan pabrik yang penuh debu dan getaran. Gambar 2 menunjukkan bearing UC205 yang digunakan sebagai objek pengujian pada penelitian ini.



Gambar 3. Gearset Konveyor

Gearset pada sistem ini berfungsi mentransmisikan daya dan torsi dari motor ke roll konveyor melalui rangkaian rantai dan sprocket. Gearset juga berperan penting dalam menjaga sinkronisasi gerak dan efisiensi kerja konveyor. Gangguan pada gearset dapat menyebabkan ketidakseimbangan operasi, getaran abnormal, bahkan penghentian sistem secara tiba-tiba. Gambar 3 memperlihatkan posisi dan tampilan fisik gearset yang menjadi objek pengamatan.

2.2 Validasi Sensor

Untuk memastikan keakuratan data yang diperoleh dari sensor utama sistem (ADXL335 untuk getaran dan sensor infra merah untuk RPM), dilakukan proses validasi menggunakan alat ukur standar industri. Validasi dilakukan dengan cara membandingkan hasil pembacaan sensor sistem dengan alat ukur kalibrasi, yaitu vibration meter dan digital tachometer.



Gambar 4. Validasi Sensor Getaran

Pada pengujian validasi getaran, data yang diukur oleh sensor ADXL335 dibandingkan dengan hasil pengukuran vibration meter tipe SW-65A sebagaimana terlihat pada Gambar 4. Pengukuran dilakukan pada posisi dan waktu yang sama untuk memperoleh hasil perbandingan yang akurat.




Gambar 5. Validasi Sensor RPM

Validasi data kecepatan putar (RPM) dilakukan menggunakan digital tachometer (Gambar 5). Hasil pengukuran RPM roll dari sensor sistem divalidasi dengan pembacaan langsung pada roll konveyor menggunakan tachometer tersebut. Hasil perbandingan antara sensor sistem dan alat ukur validasi menunjukkan bahwa deviasi hasil pengukuran berada dalam batas toleransi, sehingga data yang diperoleh dari sistem akuisisi dapat digunakan untuk proses analisis dan klasifikasi kondisi bearing serta gearset.

2.3 Akuisisi Data

Data getaran diperoleh dari sensor ADXL335 yang dipasang pada housing bearing untuk merekam percepatan pada sumbu X, Y, dan Z. Sementara itu, kecepatan rotasi (RPM) motor dan roll diukur menggunakan sensor E18-D80NK yang bekerja berdasarkan pantulan cahaya inframerah. Mikrokontroler ESP32-S3 digunakan untuk membaca sinyal analog dari ADXL335 dan pulsa digital dari E18-D80NK, kemudian mengirimkan data secara berkala ke server melalui koneksi Wi-Fi[2], [3].



Gambar 6. Arsitektur Sistem

2.4 Identifikasi Kerusakan Bearing

Data getaran dari ADXL335 diproses menggunakan algoritma *Fast Fourier Transform (FFT)* untuk mentransformasikan sinyal dari domain waktu ke domain frekuensi[2], [3]. Hasil spektrum dibandingkan dengan frekuensi karakteristik bearing, yaitu *Ball Pass Frequency Outer (BPFO)*, *Ball Pass Frequency Inner (BPFI)*, *Ball Spin Frequency (BSF)*, dan *Fundamental Train Frequency (FTF)*, yang dihitung berdasarkan parameter geometri bearing UC205 dan kecepatan rotasi[3], [5], [6]. Keberadaan puncak amplitudo pada frekuensi tersebut menjadi indikator kerusakan.

$$BPFO = \frac{n}{2} \cdot fr \cdot \left(1 - \frac{d \cdot \cos \theta}{D}\right)$$

$$BPFI = \frac{n}{2} \cdot fr \cdot \left(1 + \frac{d \cdot \cos \theta}{D}\right)$$

$$BSF = \frac{D}{2d} \cdot fr \cdot \left(1 - \left(\frac{d \cdot \cos \theta}{D}\right)^2\right)$$


$$FTF = \frac{1}{2} \cdot fr \cdot \left(1 - \frac{d \cdot \cos \theta}{D}\right)$$

2.5 Klasifikasi Kondisi Gearset

Data RPM motor dan roll dianalisis untuk mengukur selisih performa sistem transmisi. Data kemudian dinormalisasi dan digunakan sebagai input dalam algoritma KNN, yang mengklasifikasikan kondisi gearset ke dalam tiga kategori: *Normal*, *Aus*, dan *Terputus*. Nilai parameter *K* ditentukan berdasarkan hasil tuning terhadap nilai akurasi dan error rate[8].

2.6 Antarmuka Sistem

Hasil identifikasi dan klasifikasi ditampilkan melalui *Graphical User Interface (GUI)* berbasis Python. Antarmuka ini menampilkan grafik FFT, status kondisi bearing, grafik RPM motor dan roll, serta klasifikasi kondisi gearset. Sistem dirancang berjalan secara otomatis dan periodik, dengan siklus monitoring real-time selama mesin beroperasi[2].



Gambar 7. User Interface

III. HASIL DAN PEMBAHASAN

Penelitian ini menghasilkan sistem monitoring kondisi bearing dan gearset yang diuji menggunakan data aktual hasil akuisisi selama kegiatan penelitian di perusahaan produsen pupuk. Analisis dilakukan secara bertahap mulai dari akuisisi, transformasi sinyal, klasifikasi, hingga visualisasi hasil[1], [2].


3.1 Hasil Akuisisi Data

Sistem mengumpulkan data getaran menggunakan sensor ADXL335 yang dipasang pada housing bearing, dan data RPM menggunakan sensor E18-D80NK yang dipasang pada poros motor dan roll. Mikrokontroler ESP32-S3 digunakan untuk membaca sinyal dan mengirimkannya ke server secara berkala[2].

Data dikumpulkan sebanyak 6.500 sampel untuk masing-masing parameter getaran (X, Y, Z) dan RPM, dengan interval 1 detik saat sistem berjalan. Data ini menjadi dasar untuk proses analisis berikutnya[2], [3].

3.2 Hasil Transformasi FFT untuk Bearing


Sinyal getaran dari bearing dikumpulkan menggunakan sensor ADXL335 pada sumbu Z, dengan frekuensi sampling sebesar 128 Hz dan jumlah 128 sampel per detik[2]. Gambar 8 menunjukkan data getaran dalam domain waktu yang mencerminkan fluktuasi percepatan akibat gerakan mekanis bearing saat mesin beroperasi.



Gambar 8. Sinyal Percepatan Sumbu Z pada Domain Waktu

Analisis selanjutnya dilakukan dengan mentransformasikan data tersebut ke domain frekuensi menggunakan algoritma Fast Fourier Transform (FFT). Transformasi ini bertujuan untuk mengidentifikasi komponen-komponen frekuensi dominan yang dapat mengindikasikan adanya kerusakan pada elemen bearing tertentu[2], [3], [5], [6].

Hasil dari proses FFT ditunjukkan pada Gambar 9, yang menggambarkan spektrum amplitudo terhadap frekuensi. Pada grafik tersebut juga ditandai lokasi frekuensi karakteristik bearing UC205, yaitu:



Gambar 9. Spektrum FFT Dari Sinyal getaran Bearing


Puncak amplitudo yang muncul mendekati frekuensi BPFO menunjukkan adanya getaran dominan yang berkaitan dengan elemen luar bearing. Hal ini dapat dijadikan indikasi bahwa kerusakan terjadi pada outer race bearing. Penandaan garis vertikal berwarna pada grafik mempermudah identifikasi dan interpretasi visual terhadap potensi lokasi kerusakan[2].

3.3 Hasil Klasifikasi KNN untuk Gearset


Data kecepatan putaran (RPM) dari motor dan roll konveyor dikumpulkan menggunakan sensor E18-D80NK[2]. Data tersebut kemudian diproses untuk menghitung selisih RPM sebagai indikator kondisi gearset[8]. Selisih kecil menunjukkan kondisi normal, selisih sedang menandakan aus, dan selisih besar atau RPM roll ≈ 0 mengindikasikan kondisi terputus.

Sebelum digunakan untuk pelatihan model, data RPM dilakukan proses filtering, pelabelan manual berdasarkan kondisi nyata, dan normalisasi menggunakan metode Min-Max Scaling ke rentang [0, 1]. Hal ini bertujuan untuk menyeragamkan skala data dan menghindari dominasi fitur tertentu saat digunakan dalam algoritma K-Nearest Neighbors (KNN)[8].

Dataset yang telah disiapkan terdiri dari 3.000 data bersih, yang kemudian dibagi menjadi 70% data latih dan 30% data uji menggunakan metode hold-out validation. Proses klasifikasi menggunakan nilai $K = 5$ berdasarkan hasil tuning yang menunjukkan nilai akurasi tertinggi dan error rate paling rendah[8].



Gambar 10. Confusion Matrix Hasil Evaluasi Model KNN



Gambar 11. Decision Boundary Hasil Klasifikasi KNN

Hasil klasifikasi ditampilkan pada Gambar 10 berupa confusion matrix, yang menunjukkan bahwa model mampu mengklasifikasikan data kondisi Normal dan Terputus secara sempurna (akurasi 100%). Namun, pada kondisi Aus, terdapat sejumlah sampel yang salah diklasifikasikan sebagai Normal, yang menunjukkan bahwa fitur pembeda pada kondisi Aus dan Normal masih cukup berdekatan.


Untuk memperjelas visualisasi pemisahan antar kelas, Gambar 11 memperlihatkan decision boundary hasil klasifikasi KNN dalam ruang dua dimensi, di mana sumbu X merupakan nilai RPM motor dan sumbu Y merupakan nilai RPM roll (keduanya sudah dinormalisasi). Setiap kelas ditunjukkan dengan warna berbeda:

Distribusi titik-titik data terlihat terpisah cukup jelas, terutama pada kondisi Terputus yang memiliki selisih RPM ekstrem. Area batas klasifikasi dibentuk secara fleksibel sesuai prinsip dasar KNN yang membagi wilayah berdasarkan jarak ke tetangga terdekat[8].

3.4 Tuning Nilai K pada Algoritma KNN


Setelah proses klasifikasi awal, dilakukan tuning parameter K untuk menemukan nilai yang memberikan performa terbaik. Percobaan dilakukan dengan variasi nilai K dari 1 hingga 20 dan dievaluasi menggunakan teknik cross-validation[8].

Gambar 12 menunjukkan hubungan antara nilai K dan akurasi model[8]. Terlihat bahwa akurasi tertinggi diperoleh pada $K = 5$, dan menurun perlahan setelahnya, mengindikasikan bahwa nilai tersebut merupakan titik optimal.



Gambar 12. Grafik Akurasi Terhadap Variasi Nilai K

Gambar 13 menunjukkan error rate terhadap nilai K. Sama seperti pada grafik akurasi, error rate mencapai titik minimum pada $K = 5$. Nilai K yang terlalu kecil menyebabkan overfitting, sedangkan nilai terlalu besar menyebabkan generalisasi yang buruk (*underfitting*)[8].



Gambar 13. Grafik Error Rate Terhadap Variasi Nilai K

Berdasarkan kedua grafik tersebut, dipilih nilai $K = 5$ untuk implementasi akhir karena memberikan keseimbangan terbaik antara akurasi dan stabilitas prediksi[8].

IV. KESIMPULAN

Penelitian ini telah berhasil merancang dan mengimplementasikan sistem identifikasi kerusakan bearing dan klasifikasi kondisi gearset pada roll konveyor Robo Arm Palletizer menggunakan pendekatan analisis frekuensi dan algoritma K-Nearest Neighbors (KNN). Sistem identifikasi bearing memanfaatkan hasil transformasi Fast Fourier Transform (FFT) untuk mendeteksi frekuensi karakteristik seperti BPFO, BPFI, BSF, dan FTF. Hasil pengujian menunjukkan bahwa frekuensi dominan pada spektrum FFT sesuai dengan frekuensi karakteristik yang dihitung, mengindikasikan efektivitas pendekatan ini dalam mengidentifikasi lokasi kerusakan bearing.

Untuk klasifikasi kondisi gearset, sistem menggunakan parameter RPM dari motor dan roll sebagai fitur input ke dalam algoritma KNN. Hasil evaluasi menunjukkan bahwa model KNN dengan $K = 5$ mampu mencapai akurasi hingga 94%, dengan performa klasifikasi yang tinggi terutama pada kondisi Normal dan Terputus. Sistem yang dikembangkan terintegrasi dengan antarmuka GUI berbasis Python untuk menampilkan status kondisi komponen secara real-time. Dengan demikian, sistem ini diharapkan dapat menjadi solusi pemantauan kondisi yang efektif serta mendukung implementasi Industry 4.0 pada sektor manufaktur.

REFERENSI

- [1] C. Puerto-Santana, C. Ocampo-Martinez, and J. Diaz-Rozo, "A novel model-based Cauchy-Schwarz divergence condition indicator for gears monitoring during fluctuating speed conditions," *J. Sound Vib.*, vol. 592, p. 118610, Dec. 2024, doi: 10.1016/j.jsv.2024.118610.
- [2] P. Gao, Q. Yan, H. Liu, C. Xiang, and K. Chen, "Research on fault characteristics and signal transfer path mechanism of the gear transmission system," *Mech. Syst. Signal Process.*, vol. 228, p. 112471, Apr. 2025, doi: 10.1016/j.ymssp.2025.112471.
- [3] W. M. Needelman and E. V. Zaretsky, "Recalibrated Equations for Determining Effect of Oil Filtration on Rolling Bearing Life," *Tribol. Trans.*, vol. 58, no. 5, pp. 786–800, Sep. 2015, doi: 10.1080/10402004.2015.1005857.
- [4] Ma. Del Rosario Bautista-Morales and L. D. Patiño-López, "Acoustic detection of bearing faults through fractional harmonics lock-in amplification," *Mech. Syst. Signal Process.*, vol. 185, p. 109740, Feb. 2023, doi: 10.1016/j.ymssp.2022.109740.
- [5] L. Magadán, C. Ruiz-Cárcel, J. C. Granda, F. J. Suárez, and A. Starr, "Explainable and interpretable bearing fault classification and diagnosis under limited data," *Adv. Eng. Inform.*, vol. 62, p. 102909, Oct. 2024, doi: 10.1016/j.aei.2024.102909.
- [6] Q. Zhang *et al.*, "Fault Impulse Inference and Cyclostationary Approximation: A feature-interpretable intelligent fault detection method for few-shot unsupervised domain adaptation," *Reliab. Eng. Syst. Saf.*, vol. 253, p. 110568, Jan. 2025, doi: 10.1016/j.ress.2024.110568.
- [7] Q. Zhang *et al.*, "Inference and Quantification of Cyclostationary Impulses: A novel noise-sensitive mixed Gaussian cyclostationary model for compound fault detection," *Mech. Syst. Signal Process.*, vol. 229, p. 112501, Apr. 2025, doi: 10.1016/j.ymssp.2025.112501.
- [8] F. Yu, J. Liu, and D. Liu, "An approach for fault diagnosis based on an improved k-nearest neighbor algorithm," in *2016 35th Chinese Control Conference (CCC)*, Chengdu: IEEE, Jul. 2016, pp. 6521–6525. doi: 10.1109/ChiCC.2016.7554383.