

Deteksi Kavitasasi Pompa Sentrifugal Menggunakan Metode Decision Trees Berbasis Sinyal Getaran

Berli Paripurna Kamiel*, Muhammad Nadziful Malik, Krisdiyanto

Program Studi Teknik Mesin Fakultas Teknik, Universitas Muhammadiyah Yogyakarta,
Kampus Terpadu UMY, Jl. Brawijaya, Kasihan, Bantul, Yogyakarta, Indonesia 55183

Abstrak

Pompa sentrifugal adalah sebuah mesin fluida yang banyak digunakan di dunia industri yang dalam penggunaannya kerap terjadi kavitasasi. Kavitasasi berdampak pada penurunan performa pompa sehingga dapat mengganggu proses produksi. Oleh karena itu dibutuhkan metode deteksi kavitasasi yang efektif dan akurat. Pada umumnya deteksi kavitasasi berbasis sinyal getaran menggunakan analisis spektrum. Namun demikian metode tersebut tidak efektif karena menghasilkan spektrum yang kontinyu dan tersebar pada bentang frekuensi lebar. Hal ini menyebabkan deteksi kavitasasi yang berdasarkan pada peak amplitudo frekuensi karakteristik menjadi sulit dilakukan. Penelitian ini bertujuan mengembangkan metode deteksi kavitasasi melalui pendekatan machine learning dengan algoritma decision trees berbasis sinyal getaran. Tidak seperti pada analisis spektrum, metode deteksi ini lebih efektif karena berdasarkan pada klasifikasi pola sinyal getaran dan lebih mudah digunakan karena memberikan status kavitasasi atau non-kavitasasi secara langsung. Sinyal getaran direkam dari sebuah akselerometer yang diletakkan pada tutup impeler pompa sentrifugal pada sebuah rig uji sistem perpipaan loop tertutup. Sembilan parameter statistik diekstrak dari domain waktu sinyal getaran kemudian digunakan sebagai input decision trees. Hasil penelitian menunjukkan bahwa decision trees dengan menggunakan parameter statistik terpilih, efektif mendeteksi empat status kondisi pompa dengan tingkat akurasi mencapai 97,2% sedangkan dalam perspektif mendeteksi antara kondisi non-kavitasasi dan kavitasasi akurasinya mencapai 100%.

Kata kunci: decision trees; machine learning; kavitasasi; pompa sentrifugal; sinyal getaran

Abstract

[Title: Cavitation Detection Of The Centrifugal Pump Using Decision Trees Method Based on Vibration Signal] A Centrifugal pump is one of the fluid machines widely used in the industries. Cavitation is one of the major disadvantages of pump operation. It has an impact on reducing pump performance which can disrupt the production process. Therefore, an effective and accurate cavitation detection method is needed. In general, the cavitation detection method based on vibration signals uses frequency spectrum analysis. However, it is ineffective since it gives a continuous spectrum and the peaks spread over the wide frequency band. Thus cavitation detection based on the peaks of a characteristic frequency is not possible. This study proposes decision trees to detect centrifugal pumps' cavitation status based on a classification approach. The proposed method is more effective than spectrum analysis since it is based on the classification of vibration signals, which gives a direct result. The vibration signal is recorded from an accelerometer mounted on the impeller cap of the centrifugal pump on a closed-loop piping system test rig. Nine statistical parameters are extracted from the vibration waveform and used as decision trees' input. The results show that decision trees using selected statistical parameters effectively detect four pump's conditions where accuracy reaches 97.2%. Meanwhile, in the perspective of detecting between non-cavitation and cavitation conditions, the accuracy achieves 100%.

*) Penulis Korespondensi.
E-mail: berlikamiel@umy.ac.id

Keywords: decision trees; machine learning; cavitation; centrifugal pump; vibration signal

1. Pendahuluan

Pompa sentrifugal berperan sangat penting di dunia industri karena terletak pada jalur-jalur kritis dalam proses produksi. Salah satu problem pompa sentrifugal ketika beroperasi adalah kavitasi, yaitu fenomena dimana tekanan statik fluida turun di bawah tekanan uapnya yang berakibat terbentuknya gelembung uap di dalam fluida. Ketika pecah, gelembung uap menghasilkan gelombang-kejutan yang merusak sudu dan berpotensi menurunkan kinerja pompa secara drastis (Dong dkk., 2019) Oleh karena itu, dibutuhkan metode yang efektif untuk memantau kondisi pompa sentrifugal secara intensif. Telah dipahami bahwa sinyal getaran dapat digunakan untuk mengetahui kondisi kerusakan pada pompa sentrifugal. Melalui sinyal getaran dari pompa sentrifugal, indikasi awal fenomena kavitasi dapat diketahui dengan menganalisis karakteristik sinyal getaran akibat gelembung uap yang terbentuk pada saat kavitasi (Al-Obaidi & Ramadhan, 2020).

Analisis sinyal getaran pada kavitasi dapat dilakukan menggunakan domain waktu (Al Tobi & Al Sabari, 2016) dan domain frekuensi (Zhang dkk., 2015). Namun demikian metode tersebut membutuhkan pengalaman seorang ahli dalam menterjemahkan sinyal dan memutuskan terjadinya kavitasi. Hal ini tidak dapat dilakukan oleh operator di lapangan sehingga diperlukan metode yang lebih mudah digunakan, efektif dan berlaku umum.

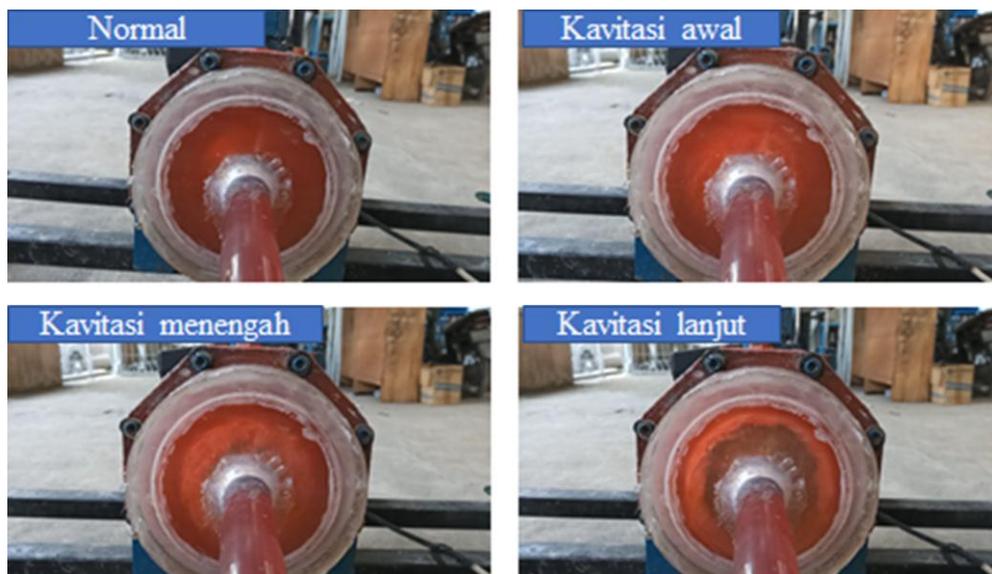
Deteksi kerusakan berbasis klasifikasi telah banyak digunakan diantaranya: deteksi cacat bantalan menggunakan modifikasi KNN (Sharma dkk., 2018), deteksi cacat roda gigi menggunakan naïve Bayes dan decision trees (Sreenath dkk., 2015) dan diagnosis kerusakan pada motor induksi menggunakan support

vector machine (Pan dkk., 2016). Metode deteksi kerusakan berbasis klasifikasi relatif mudah digunakan karena memberikan hasil langsung tanpa analisis lebih lanjut. Metode ini menggunakan algoritma pengenalan pola yang menggunakan sebuah set data-latih untuk membentuk sebuah model yang dapat digunakan untuk mengklasifikasi set data-uji kedalam kelas-kelas yang sesuai.

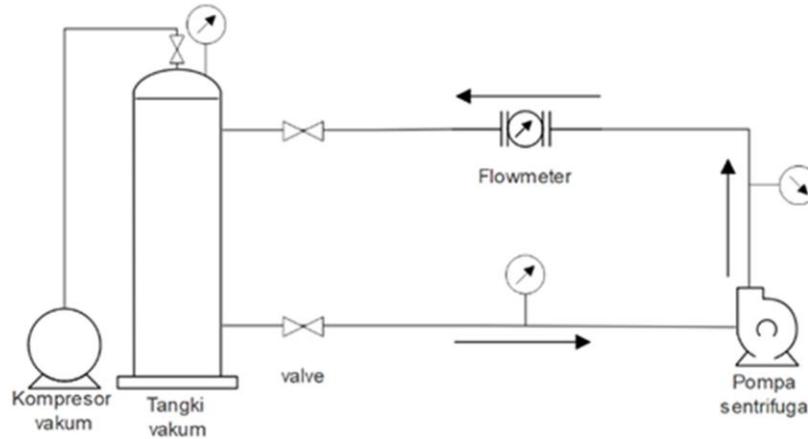
Salah satu algoritma pengenalan pola adalah decision trees yang unggul karena dapat mengeliminasi jumlah perhitungan maupun data yang tidak diperlukan selama jumlah kelas dan kriteria yang digunakan tidak terlalu banyak (Ahmed & Nandi, 2020). Decision trees merupakan sebuah classifier yang dinyatakan sebagai sebuah metode pembagian berulang dan telah diterapkan untuk mendeteksi kerusakan bantalan (Kale dkk., 2013; Senanayaka dkk., 2017), diagnosis kerusakan bilah turbin angin (Arockia Dhanraj & Sugumaran, 2016), dan deteksi kerusakan pada kompresor (Golmoradi dkk., 2017). Penelitian yang berkaitan dengan algoritma decision trees untuk mendeteksi kerusakan mesin-mesin rotari telah banyak dilakukan. Namun demikian tidak ditemukan penelitian yang membahas secara spesifik deteksi berbagai level kavitasi pada pompa sentrifugal.

Tahap penting dalam pembentukan model decision trees adalah seleksi parameter yang umumnya menggunakan metode pemangkasan atau metode pruning. Metode pruning membuat decision trees menjadi lebih ringkas dan terhindar dari problem overfitting namun demikian berpotensi menurunkan tingkat akurasi (Mohamed dkk., 2012).

Penelitian ini mengusulkan algoritma decision trees untuk mengklasifikasi tiga level kavitasi pada pompa sentrifugal. Kondisi operasi pompa normal (non-



Gambar 1. Variasi kondisi pompa sentrifugal



Gambar 2. Skema rig uji

kavitasi) digunakan sebagai baseline dan sembilan parameter statistik digunakan sebagai input decision trees. Seleksi parameter dilakukan menggunakan metode pruning dan seleksi berbasis binomial coefficient. Hasil seleksi parameter digunakan sebagai input decision trees kemudian akurasi klasifikasinya dianalisis dan dibandingkan.

2. Metode Penelitian

2.1. Model Eksperimen Dan Rig Uji

Model eksperimen adalah fenomena kavitasi yang terjadi pada sebuah pompa sentrifugal dengan volut spiral. Desain parameter eksperimen adalah debit $Q = 140$ L/menit, head $H = 42$ m, kecepatan poros $n = 2850$ RPM, daya $P = 1,5$ HP

Gulich (2010) menyatakan bahwa head drop dapat digunakan sebagai standar penentuan kavitasi pada pompa. Level 1, kavitasi awal, adalah Net Positive Suction Head (NPSH1) (sampai dengan 1% head drop), level 2, kavitasi menengah, adalah NPSH3 (1%-3% head drop), dan level 3, kavitasi lanjut, adalah di atas 3% head drop. Representasi visual kondisi operasi normal dan tiga level kavitasi dapat dilihat pada Gambar 1 dimana level kavitasi ditunjukkan oleh kuantitas gelembung uap di dalam fluida pada sisi hisap pompa.

Rig uji kavitasi dirancang dan dibuat pada Laboratorium Manufaktur Universitas Muhammadiyah Yogyakarta, ditunjukkan pada skema Gambar 2. Rig uji komponen utamanya terdiri dari sebuah pompa

sentrifugal, kompresor vakum, tangki vakum, pressure gauge, flowmeter dan katup bola. Semua komponen tersebut dirangkai membentuk sebuah sistem jalur perpipaan loop tertutup.

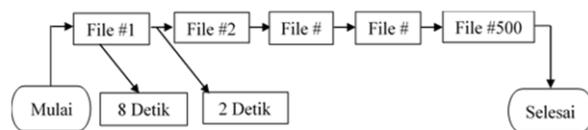
2.2 Akuisisi Sinyal Getaran

Sebuah sensor akselerometer type piezoelektrik dari Bruel & Kjaer diletakkan pada tutup impeler yang merekam getaran dalam arah aksial. Sistem data akuisisi 24 bit/4 kanal (National Instrument 9234) digunakan untuk merekam sinyal getaran dari akselerometer pada kecepatan sampling 25600 Hz.

Sejumlah 500 data sinyal getaran untuk setiap variasi level kavitasi direkam dengan waktu perekaman setiap data adalah 8 detik dengan jeda antar perekaman adalah 2 detik. Skema perekaman ditunjukkan pada Gambar 3. Jumlah total data sinyal getaran yang diperoleh adalah 2000 data untuk semua variasi kondisi.

2.3. Ekstraksi Parameter Statistik

Sembilan buah parameter statistik yaitu standar deviasi, kurtosis, skewness, standard error, mean, minimum, maximum, sum dan range diekstrak dari domain waktu sinyal getaran dari semua variasi kondisi pompa. Parameter tersebut adalah parameter yang terletak pada nodal tertinggi dari decision trees classifier pada



Gambar 3. Skema proses perekaman

Tabel 1. Parameter statistik pilihan

No	Penulis	Parameter Terbaik
1	Amarnath dkk. (2013)	Skewness dan Mean
2	Kale dkk. (2013)	Kurtosis, Standard error dan Minimum
3	Arockia Dhanraj & Sugumaran (2016)	Sum, Maximum, Standar deviasi dan Range.
4	(Sakthivel dkk., 2010)	Standard error dan Minimum

Perbaikan kelas	Normal	374				100%
	Kavitasi awal		356		15	96%
	Kavitasi menengah		3	379	4	98%
	Kavitasi lanjut		13	5	350	95%
		Normal	Kavitasi awal	Kavitasi menengah	Kavitasi lanjut	akurasi

Gambar 4. Confusion matrix data-latih

Perbaikan kelas	Normal	126				100%
	Kavitasi awal		124	1	4	96%
	Kavitasi menengah			113		100%
	Kavitasi lanjut		7		125	95%
		Normal	Kavitasi awal	Kavitasi menengah	Kavitasi lanjut	akurasi

Gambar 5. Confusion matrix data-uji

beberapa penelitian sebelumnya seperti yang ditampilkan pada Tabel 1.

Setelah menghitung parameter statistik domain waktu, total jumlah data dibagi menjadi dua yaitu data-latih sejumlah 75% dan data-uji sebanyak 15%. Pemilihan data-latih dan data-uji dilakukan secara random. Data-latih digunakan untuk melatih model klasifikasi *decision trees* dan selanjutnya diuji tingkat akurasi menggunakan data-uji.

2.4. Pembentukan Dan Pemangkasan *Decision Trees*

Decision trees adalah algoritma *machine learning* yang digunakan untuk mengklasifikasikan data kedalam kelas dan merepresentasikan hasilnya kedalam sebuah diagram alir yang berbentuk seperti sebuah pohon keputusan. Proses pembentukan *decision trees classifier* terdiri dari dua tahapan utama yaitu membangun *classifier* dan memangkas *classifier* (Ahmed & Nandi, 2020).

Pada tahap membangun *decision trees classifier*, sebanyak ±375 data-uji dari 9 parameter statistik untuk 4 kondisi pompa yaitu kondisi normal, kavitasi-awal, kavitasi-menengah dan kavitasi-lanjut, disiapkan dalam bentuk matriks ber-orde 1500 x 9. Matriks ini digunakan sebagai input algoritma klasifikasi *decision tress*.

Algoritma *decision trees* diawali dengan memilih parameter terbaik menggunakan metode *atribute selection measure* (ASM). Kedua, parameter yang dipilih pada langkah pertama digunakan sebagai *nodal*-keputusan dan selanjutnya memisahkan *set* data menjadi *subset* yang lebih kecil. Langkah terakhir adalah membangun *decision tress* dengan mengulangi langkah kedua untuk setiap *nodal*-anak sampai dengan salah satu kondisi berikut tercapai: tidak ada parameter tersisa, tidak ada sampel (*instance*) tersisa atau semua *tuples* nilai parameternya sama.

ASM adalah metode heuristik untuk memilih kriteria pemisahan (*splitting*) yang mempartisi data berdasarkan perhitungan *information gain*. Perhitungan *information gain* berdasarkan pada konsep entropy (E) yang mengukur ketidakmurnian data input. Entropy dapat dihitung dengan persamaan (1),

$$E = -p \log_2 p - q \log_2 q \tag{1}$$

dengan p dan q adalah berturut-turut probabilitas sukses dan gagal pada sebuah *nodal*. Sedangkan *information gain* (IG) didapat dengan menggunakan persamaan (2),

$$IG = E(nodal - induk) - E_{avg}(nodal - anak) \tag{2}$$

dimana E_{avg} adalah entropy rata-rata.

Setelah membangun *decision trees*, selanjutnya adalah memangkas beberapa *nodal* pada pohon asli. Pada setiap *nodal*, cabang yang dipangkas adalah cabang yang mempunyai peningkatan terendah tingkat kesalahan. Metode *pruning* bertujuan untuk mengurangi *overfitting* pada sebuah *classifier*. Dengan adanya metode *pruning* pohon berlebih direduksi menjadi pohon dengan ukuran lebih kecil (*subtree*) dengan cara memangkas cabang-cabang yang tidak berkontribusi terhadap tingkat akurasi. Algoritma *decision trees* dan *pruning* diprogram menggunakan Matlab 2018b dengan memanfaatkan fungsi-fungsi pada paket *add-on Statistics and Machine Learning Toolbox*.

Binomial coefficient (BC) merupakan teknik mengkombinasikan sejumlah parameter ‘r’ dari keseluruhan parameter ‘n’ yang digunakan, ditunjukkan pada persamaan 3. *Binomial* merupakan teori dasar untuk melakukan analisis matematis probabilitas seperti yang

sering diaplikasikan dalam statistik dan pemodelan data. Dengan teknik ini pengkombinasian parameter akan merata dan tidak ada perulangan dalam mengkombinasikan parameter statistik.

$$BC = \frac{n!}{r!(n-r)!} \quad (3)$$

3. Hasil dan Pembahasan

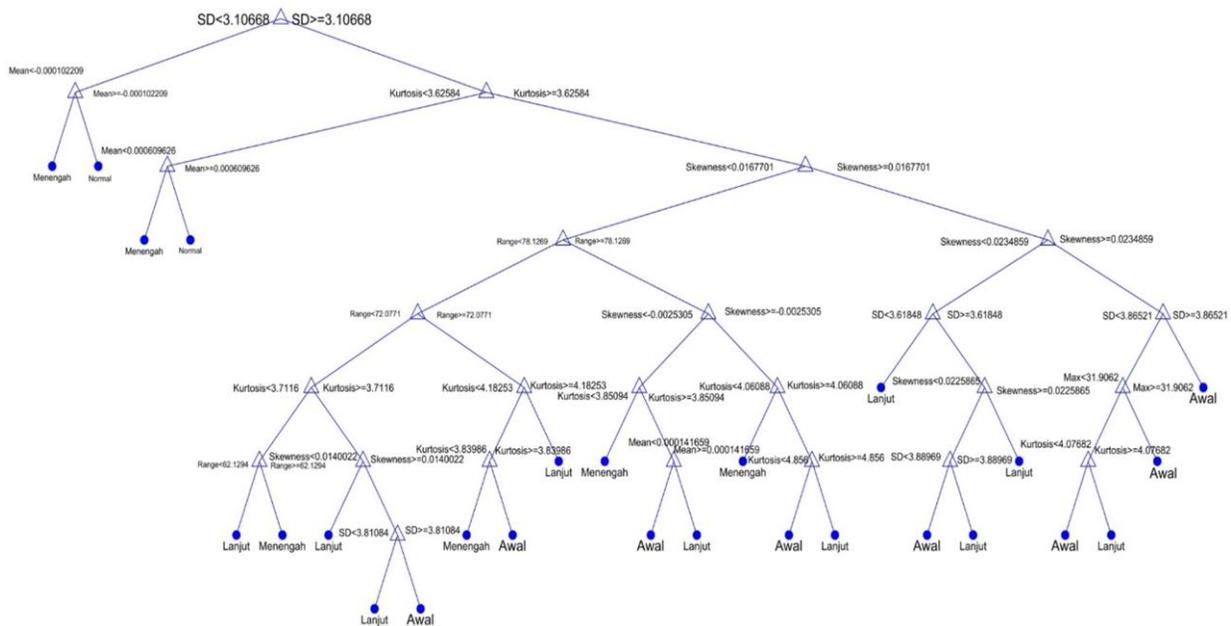
Akurasi klasifikasi hasil pelatihan menggunakan 9 parameter statistik disajikan dalam bentuk *confusion matrix* yang ditampilkan pada Gambar 4. *Confusion matrix* menunjukkan kesalahan klasifikasi sebanyak 41 sampel. Kesalahan terjadi pada klasifikasi kelas kavitas awal, kelas kavitas menengah dan kelas kavitas lanjut. Tidak terdapat kesalahan klasifikasi pada kelas kondisi normal. Hasil ini menunjukkan bahwa *decision trees* dapat mendeteksi kondisi kavitas secara efektif dimana secara umum akurasi klasifikasi mencapai 97,3 %. Tingkat akurasi untuk klasifikasi kondisi normal bahkan mencapai akurasi maksimum 100% yang artinya metode ini dapat mengenali secara tepat kapan terjadinya kavitas. Kesalahan hanya terjadi pada klasifikasi berbagai variasi tingkat kavitas.

Hal serupa didapatkan pada saat menggunakan ± 125 data-uji dimana tingkat akurasi sedikit lebih tinggi yaitu 97,6 % secara umum. *Confusion matrix* untuk data-uji ditunjukkan pada Gambar 5. Akurasi klasifikasi kondisi normal tetap mencapai 100% dan akurasi maksimal juga didapatkan pada klasifikasi kavitas-menengah. Kesalahan klasifikasi terjadi pada kelas kavitas-awal dan kavitas-lanjut.

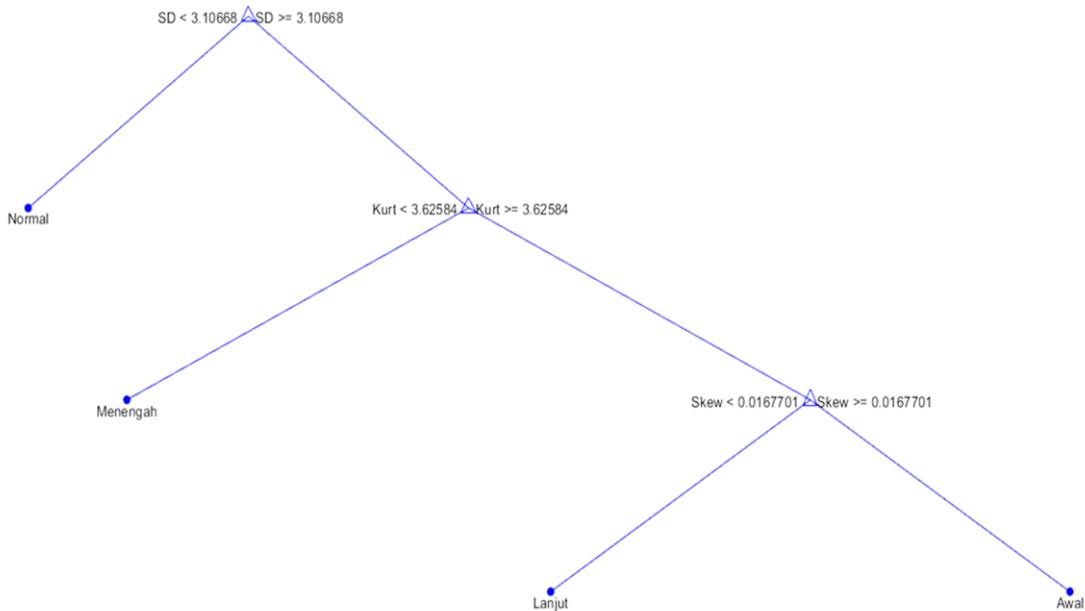
Dari perspektif data-latih dan data-uji, akurasi *decision trees* dalam mendeteksi kondisi normal mencapai 100% yang membuktikan bahwa sembilan parameter statistik yang digunakan sebagai input efektif membedakan antara kavitas dan kondisi normal. Namun demikian noise pada berbagai level kavitas membuat klasifikasi antar level kavitas tidak efektif.

Gambar 6 menunjukkan *decision trees* dengan menggunakan 9 parameter statistik. Pohon asli tersebut perlu dipangkas untuk mengeliminasi parameter yang tidak signifikan berkontribusi terhadap akurasi klasifikasi. Kontribusi parameter statistik terhadap akurasi klasifikasi dilakukan melalui metode *pruning*. Pada proses ini parameter statistik yang menduduki *nodal* tertinggi sebuah pohon menandakan bahwa parameter tersebut memiliki nilai *gain* yang paling tinggi. Semakin tinggi nilai *gain* sebuah parameter maka semakin besar informasi yang diberikan. Sehingga parameter yang menduduki *nodal* tertinggi merupakan parameter yang paling berkontribusi terhadap akurasi *classifier*.

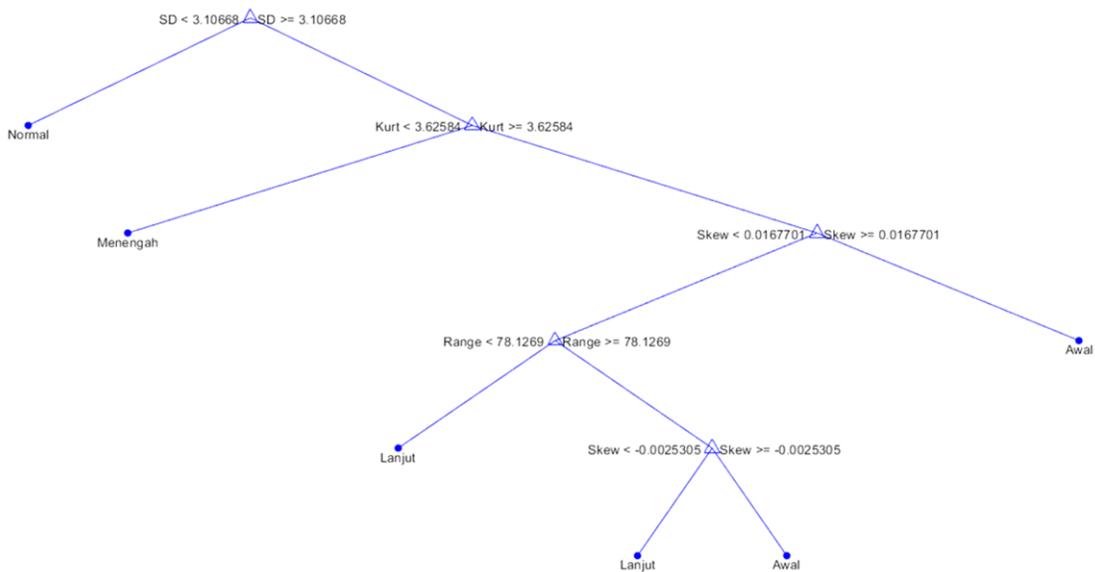
Gambar 7 adalah *decision trees* yang telah melalui proses *pruning* maksimal dimana hanya tersisa jumlah minimal parameter yang dapat mengklasifikasi semua kondisi yaitu standar deviasi, kurtosis dan *skewness*. Hasil akurasi *decision trees* pada level *pruning* maksimal adalah 95,9% untuk data-latih dan 96,0% untuk data-uji. Pohon tersebut kemudian diturunkan level *pruning*nya satu level sehingga muncul *nodal* baru yaitu parameter *range* seperti ditunjukkan pada Gambar 8. Hasil akurasi pada *subtree* tersebut adalah akurasi training sebesar 97,2% dan akurasi testing sebesar 97,0%. Dari hasil penurunan level *pruning* tersebut, parameter *range*



Gambar 6. Decision trees



Gambar 7. Subtree pada level pruning maksimal

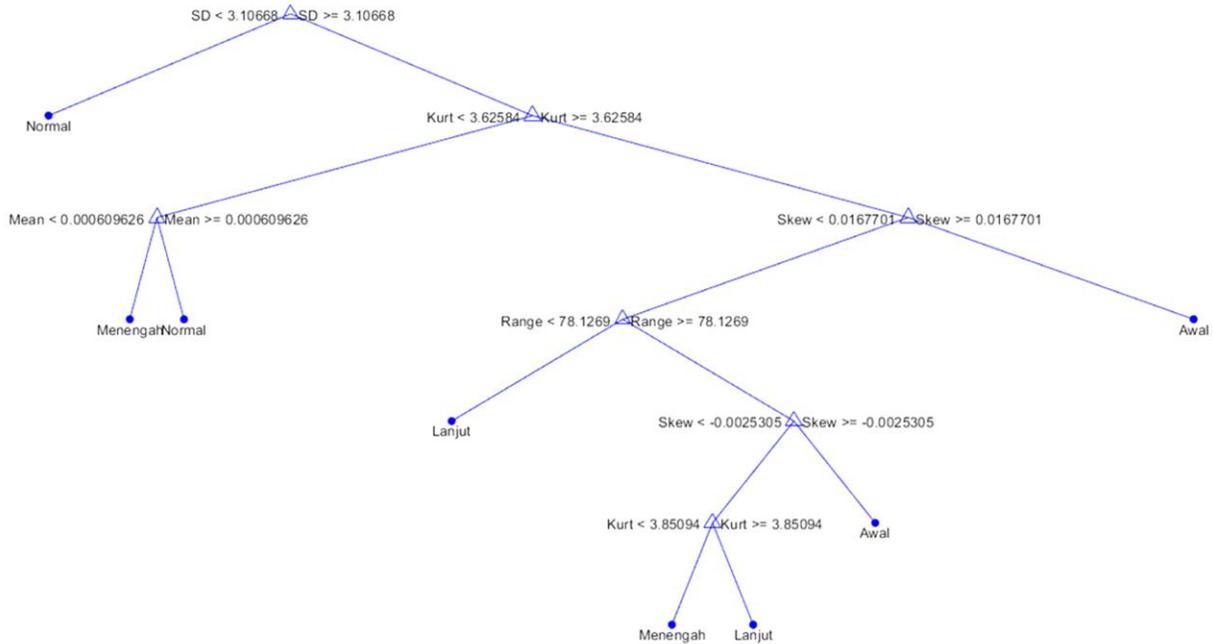


Gambar 8. Subtree penurunan satu level pruning dari level pruning maksimal

memberikan kontribusi peningkatan akurasi sebesar 2%. Selanjutnya, penurunan level *pruning* dilanjutkan dengan menurunkan satu level *pruning* seperti ditunjukkan pada Gambar 9. Dari hasil penurunan level *pruning*, muncul parameter statistik baru yaitu *mean*. Hasil akurasi pada subtree tersebut menunjukkan akurasi training sebesar 97,7% dan akurasi testing sebesar 97,4%. Dari hasil penurunan level *pruning* tersebut peningkatan akurasi classifier tidak terlalu besar, hanya sekitar 0,4%. Oleh karena itu penurunan level *pruning* berhenti pada

parameter statistik *range*. Penurunan level *pruning* berhenti ketika nodal baru yang muncul tidak terlalu berkontribusi terhadap nilai akurasi classifier

Akurasi menggunakan metode seleksi *binomial coefficient* yang ditunjukkan pada Tabel 2 menunjukkan bahwa kombinasi parameter terbaik ditunjukkan dengan kombinasi 4 parameter statistik dimana keempat parameter tersebut menghasilkan akurasi training classifier sebesar 97,1% dan akurasi testing classifier sebesar 97,2%. Jika diamati pada semua kombinasi



Gambar 9. Subtree penurunan dua level pruning dari level pruning maksimal

parameter statistik, penambahan parameter hingga mencapai kombinasi 8 parameter statistik menunjukkan hasil akurasi yang tidak jauh berbeda dimana penambahan akurasi hanya sekitar 0,6%. Dengan demikian pemilihan parameter statistik dengan metode seleksi *binomial coefficient* menunjukkan bahwa parameter yang berkontribusi paling besar terhadap akurasi *classifier* adalah *standard error*, kurtosis, *skewness* dan *range*.

Terdapat beberapa hal menarik dari hasil penelitian ini. Amarnath *dkk.* (2013) menggunakan parameter yang menduduki *nodal* tertinggi atau *root-node* yaitu parameter *mean* dalam penelitiannya tentang deteksi cacat bantalan bola. Namun demikian pada penelitian ini parameter tersebut tidak efektif. Arockia Dhanraj & Sugumaran (2016) juga menggunakan parameter yang menduduki *nodal* tertinggi yaitu *sum* pada penelitiannya tentang deteksi kerusakan bilah turbin angin. Akan tetapi, parameter *sum* yang menduduki *nodal* tertinggi tersebut juga tidak terpilih untuk mendeteksi berbagai level kavitasi pada pompa. Beberapa parameter statistik terbaik yang digunakan untuk mendeteksi kerusakan pada mesin-

mesin rotari belum tentu efektif diterapkan untuk mendeteksi berbagai level kavitasi pada pompa sentrifugal. Hal ini disebabkan perbedaan pola getaran dari objek yang diamati. Pola getaran yang dihasilkan bantalan cenderung memiliki komponen periodik, impulsif dan stasioner sedangkan pola getaran pada kavitasi bersifat acak (*random*) karena aliran fluida dan gerakan gelembung uap pada saat kavitasi bersifat acak dan non-stasioner.

Siano & Panza (2018) melaporkan berhasil menggunakan analisis spektrum untuk mendeteksi kavitasi pada pompa roda gigi (*gear pump*). Namun demikian komponen frekuensi yang mengindikasikan kavitasi tersebar pada bentang frekuensi tinggi, diantara 7 dan 14 kHz, alih-alih berbentuk diskrit sehingga terbuka potensi kesalahan deteksi oleh personel di lapangan. Metode deteksi kavitasi berbasis *machine learning* yang diusulkan pada penelitian ini memberikan hasil langsung terhadap status kavitasi pompa sehingga kesalahan deteksi oleh operator dapat dihindari.

Tabel 2. Kombinasi parameter statistik

Kombinasi	Parameter statistik									Akurasi pelatihan (%)	Akurasi pengujian (%)
	Standar deviasi	Kurtosis	Skewness	Standard error	Mean	Minimum	Maximum	Sum	Range		
8 parameter	-	√	√	√	√	√	√	√	√	97,1	97,8
7 parameter	-	√	√	√	-	√	√	√	√	97,1	97,8
6 parameter	-	√	√	√	√	√	-	-	√	97,3	97,8
5 parameter	-	√	√	√	-	-	-	√	√	97,6	97,6
4 parameter	-	√	√	√	-	-	-	-	√	97,1	97,2
3 parameter	√	√	√	-	-	-	-	-	-	95,90	96,0

4. Kesimpulan

Deteksi kavitas berbasiskan algoritma *decision trees* efektif digunakan pada pompa sentrifugal menggunakan parameter statistik terpilih yang diekstrak dari domain waktu sinyal getaran. Dua buah metode seleksi parameter statistik yaitu *pruning* dan *binomial coefficient* menunjukkan lima parameter statistik yaitu standar deviasi, *standard error*, kurtosis, *skewness* dan *range* memberikan akurasi terbaik. Kedua metode seleksi memberikan tingkat akurasi klasifikasi sekitar 97% untuk data-latih dan data-uji. Distribusi kesalahan pada *confusion matrix* menunjukkan bahwa akurasi sangat tinggi mencapai 100% dalam hal mengklasifikasi kondisi kavitas dan kondisi non-kavitas oleh karena itu metode yang diusulkan pada penelitian ini efektif dan menjanjikan untuk memonitor kondisi pompa sentrifugal.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada LP3M Universitas Muhammadiyah Yogyakarta yang telah memberikan pendanaan dalam bentuk hibah penelitian sehingga penelitian ini dapat selesai dengan baik dan lancar

Daftar Pustaka

- Ahmed, H., & Nandi, A. K. (2020). *Condition Monitoring With Vibration Signals Comprehensive Sampling And Learning Algorithms For Rotating Machines*. John Wiley & Sons Ltd.
- Al-Obaidi, & Ramadhan, A. (2020). Detection of Cavitation Phenomenon within a Centrifugal Pump Based on Vibration Analysis Technique in both Time and Frequency Domains. *Experimental Techniques*, 44(3), 329-347.
- Al Tobi, M. A. S., & Al Sabari, M. H. J. (2016). Cavitation detection of centrifugal pump using Time-Domain method. *International Journal of ENgineering Research and General Science*, 4(5), 161-167.
- Amarnath, M., Sugumaran, V., & Kumar, H. (2013). Exploiting sound signals for fault diagnosis of bearings using decision tree. *Measurement*, 46(3), 1250-1256.
- Arockia Dhanraj, J., & Sugumaran, V. (2016). Wind Turbine Blade Fault Diagnosis Using Vibration Signals through Decision Tree Algorithm. *Indian Journal of Science and Technology*, 9.
- Dong, L., Wu, K., Zhu, J.-c., Dai, C., Zhang, L.-x., & Guo, J.-n. (2019). Cavitation Detection in Centrifugal Pump Based on Interior Flow-Borne Noise Using WPD-PCA-RBF. *Shock and Vibration*, 2019, 8768043.
- Golmoradi, M., Ebrahimi, E., & Javidan, M. (2017). Fault diagnosis of compressor based on decision tree and fuzzy inference system. *Vibroengineering Procedia*, 12, 54-60.
- Gulich, J. F. (2010). Pump hydraulics and physical concepts. In *Centrifugal pumps*. Berlin, Heidelberg: Springer, 69-144.
- Kale, A., R, J., & Sugumaran, V. (2013). Roller Bearing Fault Diagnosis by Decision Tree Algorithms with Statistical Feature. *International Journal of Research in Mechanical Engineering*, 1, 1-9.
- Mohamed, W. N. H. W., Salleh, M. N. M., & Omar, A. H. (2012, 23-25 Nov. 2012). A comparative study of Reduced Error Pruning method in decision tree algorithms. Paper presented at the 2012 IEEE International Conference on Control System, Computing and Engineering.
- Pan, S., Han, T., Tan, A. C. C., & Lin, T. R. (2016). Fault Diagnosis System of Induction Motors Based on Multiscale Entropy and Support Vector Machine with Mutual Information Algorithm. *Shock and Vibration*, 2016, 5836717.
- Sakthivel, N. R., Sugumaran, V., & Babudevasenapati, S. (2010). Vibration based fault diagnosis of monoblock centrifugal pump using decision tree. *Expert Systems with Applications*, 37(6), 4040-4049.
- Senanayaka, J. S. L., Khang, H. V., & Robbersmyr, K. G. (2017, 11-14 Aug. 2017). Towards online bearing fault detection using envelope analysis of vibration signal and decision tree classification algorithm. Paper presented at the 2017 20th International Conference on Electrical Machines and Systems (ICEMS).
- Sharma, A., Jigyasu, R., Mathew, L., & Chatterji, S. (2018, 11-12 May 2018). Bearing Fault Diagnosis Using Weighted K-Nearest Neighbor. Paper presented at the 2018 2nd International Conference on Trends in Electronics and Informatics (ICOEI).
- Siano, D., & Panza, M. A. (2018). Diagnostic method by using vibration analysis for pump fault detection. *Energy Procedia*, 148, 10-17.
- Sreenath, P. G., Praveen Kumare, G., Pravin, S., Vikram, K. N., & Saimurugan, M. (2015). Automobile Gearbox Fault Diagnosis Using Naive Bayes and Decision Tree Algorithm. *Applied Mechanics and Materials*, 813-814, 943-948.
- Zhang, N., Yang, M., Gao, B., & Li, Z. (2015). Vibration Characteristics Induced by Cavitation in a Centrifugal Pump with Slope Volute. *Shock and Vibration*, 2015, 294980