

BAB I

PENDAHULUAN

1.1 Latar Belakang

Adanya sistem pemeliharaan yang tepat dapat mendukung kelancaran sebuah proses produksi yang menghasilkan produk dengan kualitas yang unggul. Perkembangan industri yang semakin canggih melahirkan berbagai macam teknologi dengan sistem yang semakin kompleks sehingga membutuhkan sistem pemeliharaan yang baik. Sistem pemeliharaan yang tepat dilakukan sebelum suatu komponen mengalami kegagalan. Pada industri yang menerapkan sistem *smart factory*, pemeliharaan prediktif dilakukan menggunakan pengenalan dari kegagalan akustik yang dapat berfungsi sebagai peringatan dini, terutama pada industri yang memiliki tingkat risiko yang cukup tinggi. Dalam sistem pemeliharaan prediktif, deteksi anomali menjadi salah satu teknik yang sangat penting dalam mendeteksi sebuah kondisi mesin melalui sinyal akustik (Tagawa dkk, 2021). Deteksi anomali berdasarkan fitur akustik mesin bersifat fleksibel dan dapat mengurangi biaya dengan cara menggunakan mikrofon sebagai alat perekam yang didekatkan ke mesin untuk mendeteksi adanya anomali akustik. Hal tersebut dapat menghindari adanya kerugian besar yang disebabkan oleh kegagalan serius serta dapat melakukan sistem perawatan dan pemeliharaan secara efektif (Wang dkk., 2021).

Pada saat mesin beroperasi, sinyal akustik dapat dihasilkan dari adanya getaran mesin. Sinyal akustik yang dihasilkan oleh mesin memuat informasi terkait sifat dari sebuah sistem yang dapat digunakan sebagai parameter dalam teori penentuan kondisi mesin (Delgado-Arredondo, 2017). Pham dkk (2020) melakukan penelitian yang berjudul "Metode Cerdas dalam Diagnosis Kegagalan Menggunakan Sinyal Akustik untuk Bantalan dalam Kondisi Kinerja yang Kompleks". Penelitian ini menggunakan sinyal akustik untuk mendiagnosis kegagalan bantalan mesin *non-drive-end shaft* pada domain waktu-frekuensi dengan menggunakan tambahan variasi nilai *Signal to Noise Ratio* (SNR) 10, 5, dan 0. Saat melakukan klasifikasi kegagalan tanpa adanya noise, tingkat akurasi

yang dihasilkan yakni rata-rata sebesar 98.77%. Sedangkan saat menggunakan tambahan noise dengan nilai SNR yang positif, menghasilkan tingkat akurasi rata-rata sebesar 97.55% (10db), 96.21% (5dB), dan 89.85% (0 dB) (Pham dkk, 2020). Pada penelitian lain yang dilakukan oleh Puspitasari dkk (2016) tentang prediksi kerusakan pada poros mesin pompa, menggunakan sinyal akustik untuk mengidentifikasi kondisi mesin *unbalance* dan normal. Penelitian ini menggunakan algoritma *Fast Fourier Transform* (FFT) untuk mengetahui adanya cacat pada komponen mesin yang dilihat berdasarkan grafik spektrum pada domain frekuensi. Akustik mesin pompa direkam dengan 3 posisi yaitu vertikal, horizontal, dan axial. Hasil penelitian menunjukkan bahwa pada kondisi normal, terdapat amplitudo terbesar pada 1xRPM dengan posisi horizontal paling tinggi daripada posisi lain. Sedangkan untuk kondisi *unbalance*, amplitudo terbesar juga terletak pada 1xRPM dengan posisi vertikal lebih tinggi daripada yang lain (Puspitasari dkk, 2016). Berdasarkan penelitian-penelitian tersebut, sinyal akustik dapat digunakan untuk mendiagnosa adanya kegagalan pada mesin sehingga akan mempermudah dalam pengambilan sampel tanpa menyentuh secara langsung ataupun membongkar mesin.

Dalam mendeteksi adanya anomali, sinyal akustik memiliki beberapa fitur yang dapat digunakan untuk membedakan sinyal sesuai dengan kondisi mesin. Secara teori dasar, terdapat dua jenis fitur akustik yakni berdasarkan domain waktu dan domain frekuensi. Fitur akustik dalam domain waktu dapat memberikan informasi dari fungsi statistik yang digunakan untuk mengekstrak fitur dari *dataset real* industri. Adapun fitur akustik dalam domain waktu antara lain yakni rms, varians dan standart deviasi, *peak value*, *kurtosis*, *shape factor*, *clearance factor*, *impulse factor*, *mean value*, *skewness* (Ahmed & Nandi, 2020). Sedangkan fitur akustik yang berasal dari domain frekuensi, bisa digunakan dengan cara mengubah sinyal akustik domain waktu menggunakan *Fast Fourier Transform* (FFT). Adapun fitur domain frekuensi yang bisa digunakan antara lain SNR, SINAD, *root mean square frequency*, *median* dan *mean frequency* (Kamiel dkk, 2019). Selain kedua jenis domain fitur akustik tersebut, terdapat fitur akustik lain yang dapat digunakan dalam mendeteksi anomali mesin yakni fitur akustik domain waktu-frekuensi/*time-*

frequency domain. Salah satu jenis fitur yang terdapat dalam domain waktu-frekuensi adalah *Mel-Frequency Cepstral Coefficients (MFCC)*. Fitur MFCC ini dapat digunakan untuk menganalisis akustik mesin yang mengandung informasi dari domain waktu dan frekuensi (Nelwamondo dkk, 2006).

Dalam penelitian yang dilakukan oleh Chuang dkk (2019), tentang deteksi kerusakan pada *water distribution pipes* dengan menggunakan fitur MFCC. Objek pada penelitian tersebut yakni pipa yang memiliki fungsi untuk mendistribusikan air yang terletak di bawah tanah. Akustik yang dihasilkan dari perangkat yang berada di pipa tersebut di rekam lalu di analisa dengan menggunakan pendekatan fitur MFCC. Adapun metode klasifier yang digunakan adalah *Convolutional Neural Network (CNN)*, yang kemudian dibandingkan dengan metode *Support Vector Machine (SVM)* dan *Knearest Neighbor (KNN)*. Hasil tingkat akurasi untuk metode CNN adalah sebesar 99,4%. Sedangkan untuk metode SVM dan KNN, masing-masing adalah sebesar 98% dan 96,8% (Chuang dkk, 2019).

Berdasarkan penelitian yang dilakukan oleh Kamiel dkk (2019), hasil klasifikasi menggunakan *machine learning* berdasarkan fitur akustik domain waktu dan domain frekuensi dapat mendeteksi adanya kavitas pada mesin pompa dengan tingkat akurasi sebesar 100%. *Machine learning* merupakan bidang ilmu komputer yang menggunakan data sebagai bahan untuk memprediksi dan menanggapi data di masa yang akan datang. Hal tersebut berkaitan erat dengan statistik komputasi, kecerdasan buatan, pengenalan pola, serta penggunaan algoritma komputer (Paluszek & Thomas, 2020). Salah satu metode *machine learning* yang dapat digunakan untuk klasifikasi adalah *Support Vector Machine (SVM)*. Dalam pemantauan dan analisa kondisi mesin (*condition monitoring*), metode SVM dapat digunakan untuk mengenali pola khusus dari sinyal akustik mesin yang didapatkan. Lalu sinyal akustik tersebut membentuk pola-pola yang akan diklasifikasikan sesuai dengan permasalahan mesin. Semakin bertambahnya waktu, SVM telah menjadi metode yang populer dalam pembelajaran mesin (*machine learning*) karena memiliki keunggulan dalam melakukan generalisasi daripada metode tradisional seperti *neural network*. Maka dari itu, metode *Support Vector Machine* telah berhasil diterapkan di berbagai macam aplikasi seperti *face detection, verification,*

text direction, klasifikasi kondisi mesin, dan lain sebagainya karena memiliki tingkat keakuratan yang cukup tinggi (Widodo & Yang, 2007).

Pada penelitian lain yang dilakukan oleh Kamiel dkk (2019), melakukan analisis kecacatan dari sebuah bantalan bola pada *fan* industri melalui metode *Support Vector Machine*. Objek penelitian tersebut adalah bantalan normal dan bantalan cacat. Fitur akustik yang digunakan sebanyak 17 yakni: *Root Mean Square (RMS)*, *Std*, *variance*, *entropy*, standar eror, *peak value*, *kurtosis*, *crest factor*, *minimum*, *skewness*, *mean*, *median*, *SINAD*, *maximum*, *range*, *mean*, *SUM*, dan *SNR*. Seluruh fitur tersebut kemudian dipilih menggunakan metode seleksi visual dengan cara menggolongkan fitur yang dapat memisahkan kelas lain tanpa *overlap* (tumpang tindih). Hasil penelitian tersebut menunjukkan tiga kombinasi fitur akustik yang terseleksi yakni *entrophy-standard error*, *standard deviasi-variance*, *rms-standard deviasi* mampu memberikan tingkat akurasi hingga 100% dalam klasifikasi kecacatan bantalan bagian lintasan dalam (Kamiel dkk, 2019)

Dalam penelitian yang dilakukan oleh (Dzilfadhilah, 2021), tentang klasifikasi kerusakan mesin pompa berdasarkan *Support Vector Machine (SVM)* dengan menggunakan data akustik. Objek penelitian tersebut adalah mesin pompa yang sudah disetel sebagai kerusakan *missalignment*, *unbalance*, dan *bearing fault*. Fitur akustik yang digunakan yakni *RMS*, *kurtosis*, *skewness*, *crest factor*, *shape factor*, dan *instaneous frequency*. Data pelatihan (*training*) yang digunakan adalah sebesar 50%, sedangkan data pengujian (*testing*) sebesar 50%. Hasil tingkat akurasi dari klasifikasi kerusakan mesin pompa dengan menggunakan SVM Linear adalah sebesar 96,7% dan SVM Quadratic sebesar 100%. Penelitian tersebut juga membuktikan bahwa metode SVM memiliki tingkat akurasi yang lebih tinggi jika dibandingkan dengan metode *decision tree* yang menghasilkan tingkat akurasi sebesar 80% dan metode KNN sebesar 76,7% (Dzilfadhilah, 2021).

Pada penelitian yang dilakukan oleh Toma dkk (2020), melakukan deteksi anomali pada *induction motors (IMs)*. Metode pemilihan fitur akustik yang digunakan yakni berupa algoritma genetik (GA), dimana hanya menggunakan sepuluh fitur akustik yang berasal dari domain waktu untuk memilih fitur terbaik yang akan digunakan untuk mengklasifikasikan ke dalam *machine learning*.

Pengklasifikasian jenis kerusakan motor dilakukan menggunakan model *machine learning* dari KNN, *decision tree*, dan *random forest*. Hasil tingkat akurasi dari masing-masing metode klasifikasi tersebut adalah sebesar 97% untuk KNN, 98% untuk *decision tree*, dan 99,7% untuk *random forest* (Toma dkk, 2020). Namun dalam penelitian ini, pemilihan fitur akustik yang dilakukan tidak melibatkan domain frekuensi.

Berdasarkan penelitian-penelitian terdahulu, perlu dilakukan pengembangan terhadap metode penggunaan dan pemilihan fitur akustik agar hasil klasifikasi yang didapatkan memiliki tingkat akurasi yang lebih tinggi serta dengan hasil pilihan fitur akustik yang terbaik. Pada penelitian ini akan dilakukan deteksi anomali pada mesin pompa berdasarkan fitur akustik dan *machine learning*. Fitur akustik yang digunakan berasal dari domain waktu, domain frekuensi, dan domain waktu-frekuensi. Pada penelitian ini dilakukan proses klasifikasi dengan *Machine Learning* yang berupa *Support Vector Machine* (SVM). Metode *machine learning* yang digunakan adalah SVM (*Support Vector Machine*). Total *dataset* setelah proses *undersampling* adalah 600 data yang terdiri atas masing-masing 300 *audio file* kondisi normal dan abnormal. *Dataset* yang digunakan memiliki 3 variasi SNR yakni -6dB, 0 dB, dan 6dB, sehingga terdapat 100 *dataset* pada tiap kondisi. Jumlah data *training* yang digunakan sebesar 70% dari total *dataset* pada setiap kondisi mesin dan 30% sisanya untuk data *testing*. Model SVM akan dievaluasi performansinya berdasarkan variasi nilai SNR dan fitur akustik. Penelitian ini diharapkan dapat memberikan referensi baru dalam penggunaan metode deteksi anomali berdasarkan fitur akustik dan *machine learning*.

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, perumusan masalah yang didapatkan adalah bagaimana performansi dari deteksi anomali mesin pompa industri berdasarkan fitur akustik dan *machine learning*?

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah untuk mengetahui performansi dari deteksi anomali mesin pompa industri berdasarkan fitur akustik dan *machine learning*.

1.4 Manfaat Penelitian

Adapun manfaat pada penelitian ini adalah sebagai berikut :

- 1) Menambah pengetahuan baru bagi siapapun yang ingin mengetahui bidang ilmu *machine learning*
- 2) Memberikan pengembangan baru dalam analisa sistem pemeliharaan prediktif

1.5 Batasan Penelitian

Adapun batasan pada penelitian ini adalah sebagai berikut :

- 1) Penggunaan dataset berupa *wavfile* dari mesin pompa industri dengan variasi nilai SNR = -6dB, 0 dB, 6dB
- 2) Penggunaan algoritma *machine learning* berupa metode *Support Vector Machine* (SVM) untuk klasifikasi kondisi abnormal atau normal

1.6 Hipotesa Penelitian

Adapun hipotesa awal dalam penelitian ini adalah sebagai berikut:

- 1) Data yang digunakan berdistribusi normal dan acak
- 2) Seleksi terhadap fitur akustik yang digunakan untuk membuat model didasarkan pada karakteristik data