

BAB I

PENDAHULUAN

1.1 Latar Belakang

Era revolusi industri 4.0 dideskripsikan sebagai revolusi atau peralihan dari produksi yang tradisional menuju ke produksi yang terpusat dan otomatisasi yang dikenal dengan *smart factory* (Samatas dkk., 2021). Adanya otomatisasi ini memberikan banyak perubahan salah satunya pada bidang *maintenance* yang mulai beralih ke *predictive maintenance* (PdM) dengan memanfaatkan *machine learning* atau *artificial intelligent* (AI). Berdasarkan hasil analisa yang dilakukan oleh Samatas dkk (2021) *predictive maintenance* dominan diminati oleh sektor produksi yang dibuktikan dengan adanya peningkatan penggunaan PdM dalam kurun waktu tahun 2011-2020 yang berdasarkan pada data publikasi dari 847 *paper*. Hal tersebut ditunjukkan melalui *trend line* yang mendekati garis eksponensial dengan nilai indeks R^2 sebesar 0,953 (Samatas dkk., 2021). Dalam *review* yang ditulis oleh Pech dkk (2021) sebuah perusahaan yang mengadopsi *predictive maintenance* sebagai metode pemeliharaan mesin akan sangat menguntungkan bagi manajemen operasional dan *engineer* (Pech dkk., 2021). Dengan memanfaatkan kecerdasan buatan seperti *machine learning* akan dapat membantu untuk melakukan pemantauan kondisi *real time* dan meminimalkan risiko terjadi *downtime* yang tidak terencana (Widodo dkk., 2017). Salah satu fitur yang umum digunakan dalam penerapan PdM adalah fitur akustik yang dinilai memiliki sensitivitas tinggi karena mampu memberikan gambaran perbedaan kondisi berdasarkan gelombang suara yang dihasilkan (Pham dkk., 2020). Dengan bantuan sensor *acoustic emission* (AE) yang diolah menggunakan fitur akustik, *engineer* dapat mengetahui adanya aktivitas abnormal seperti retakan, gesekan mekanis maupun kebocoran yang dilihat berdasarkan 2 tipe gelombang yaitu *burst* dan kontinyu (Ozevin & Yalcinkaya, 2013).

Salah satu peralatan yang dinilai rentan akan kebocoran adalah pipa. Sebagaimana fungsinya, pipa digunakan sebagai alat untuk mendistribusikan fluida

maupun gas, dimana memiliki peran untuk menyokong kelancaran dari alur sistem produksi sebuah pabrik (Pramono dkk., 2020). Pipa merupakan peralatan yang sangat penting terutama bagi jenis pabrik yang bergerak pada sektor minyak dan gas. Adanya kebocoran pipa dapat menimbulkan munculnya percikan api atau ledakan yang besar akibat adanya reaksi kimia yang terjadi (Berg-Hansen, 2022). Menurut Ozevin & Yalcinkaya (2013) melakukan analisa kebocoran pada pipa yang memuat air atau fluida lebih mudah diketahui beserta lokasinya daripada pada pipa gas (Ozevin & Yalcinkaya, 2013). Dalam penelitian tersebut, pipa yang dianalisa berfungsi untuk mendistribusi gas dalam laboratorium. Kondisi pipa yang dianalisa termasuk pada tekanan internal, ukuran kebocoran, dan tekanan tanah yang divariasikan untuk mengidentifikasi karakteristik kebocoran menggunakan sensor *acoustic emission* (AE) (Ozevin & Yalcinkaya, 2013). Pada penelitian tersebut, jenis material pipa yang digunakan adalah baja dengan 3 skenario penelitian diantaranya pipa tidak terkubur, terkubur setengah, dan terkubur seluruhnya. Pada pipa skala kecil menghasilkan amplitudo AE pada tingkat kebocoran dan kondisi pipa yang berbeda. Perbedaan gelombang yang dihasilkan dapat terjadi karena faktor jarak sensor dengan lokasi kebocoran yang dapat menurunkan sensitivitas sensor. Sedangkan pada frekuensi yang berbeda, studi numerik perlu dilakukan untuk mendapatkan koefisien redaman dan mengidentifikasi jarak sensor yang sesuai (Ozevin & Yalcinkaya, 2013).

Pada penelitian Sohaib & Kim (2019) yang berjudul "*Data Driven Leakage Detection and Classification of a Boiler Tube*" melakukan uji kebocoran pada *tube boiler* yang dianalisa menggunakan analisis *wavelet packet transform* (WPT) dan menggunakan *acoustic emission* (AE) untuk menangkap sinyal dari *tube boiler*. Dalam analisisnya, untuk meningkatkan kinerja klasifikasi dari identifikasi kebocoran maka diusulkan menggunakan model *K-Nearest Neighbor* (KNN) dan *Support Vector Machine* (SVM) yang mampu menghasilkan persentase rata-rata *accuracy* sebesar 99,2% saat pengujian dengan sinyal yang ditangkap oleh AE (Sohaib & Kim, 2019). Hal tersebut menunjukkan bahwa model KNN dan SVM merupakan model klasifikasi yang efektif digunakan dalam pengujian kebocoran untuk *tube boiler*. Sinyal akustik merupakan fitur yang juga mampu untuk mendeteksi adanya kebocoran pada pipa seperti yang dibuktikan oleh Khan dkk

(2017) yang menguji sensitivitas fitur akustik untuk memonitoring keadaan pipa yang diuji dalam laboratorium sehingga tanpa *noise* (Khan dkk., 2017). Hasil yang didapatkan selama pengolahan menggunakan fitur akustik adalah adanya kebocoran ditandai dengan hilangnya sinyal pada frekuensi 1,25 kHz yang melebihi 3 dB. Hasil tersebut ditunjukkan melalui hasil analisa *power spectral density* (PSD) (Khan dkk., 2017).

Pada penelitian sebelumnya yang dilakukan oleh Bergh-Hansen (2022) pada analisa kebocoran dengan 2 kriteria yaitu adanya kebocoran pada *vent* dan *tube*. Pada kriteria *tube* data terbagi berdasarkan skala kebisingan (*lab*, *hydr*, *hydr low*, *work*, dan *work low*). Dalam penelitian tersebut dilakukan ekstraksi data sinyal audio salah satunya menggunakan metode MFCC untuk mengekstraksi data akustik dan klasifikasi model diantaranya *Random Forest* (RF), AdaBoost, XgBoost, dan *Decision Tree* (DT) yang akan dibandingkan dengan hasil model *Convolutional Neural Network* (CNN) (Berg-Hansen, 2022). Hasil yang didapatkan untuk data *training* adalah *Random Forest* (RF) memiliki nilai rata-rata *accuracy* yang melebihi model CNN diantaranya *lab* (98,34%) dan *work* (96,94%). Selain itu Bergh-Hansen (2022) juga melakukan eksperimen dengan menambahkan data lain dan diuji menggunakan model *One-Class SVM* (OC-SVM), *Isolation Forest* (IF), dan *Local Outlier Factor* (LOF). Didapatkan hasil untuk model OC-SVM memiliki nilai *accuracy* dan *f1-score* yang paling tinggi diantara LOF dan IF. Model dapat dikatakan baik atau buruk berdasarkan pada perhitungan evaluasi performansi dari nilai tabel di *confusion matrix* yang dihasilkan (Amirneni, 2019). Untuk perumusan evaluasi performansi yang menggunakan *precision* akan dipengaruhi oleh nilai pada tabel *true positive* dan *false positive*, jika tabel *false positive* memiliki nilai yang cukup besar lebih dari 20% total data dimana hal tersebut menunjukkan ketidakmampuan model dalam mengklasifikasikan maka model dapat dikatakan buruk jika digunakan (Amirneni, 2019). Sebaliknya, jika nilai tabel *false positive* kurang dari 20% maka model dapat dikatakan baik, cukup baik atau sangat baik digunakan pada kasus tersebut.

Dalam proses identifikasi kebocoran pada pipa sebenarnya dapat dilakukan dengan menggunakan FFT yang menghasilkan spektrum dengan tampilan perbandingan antara frekuensi dengan *magnitude* (Berg-Hansen, 2022). Ada juga

yang menggunakan bantuan dari tanda *waveform* (waktu dengan *voltage*), dimana dengan ketinggian tertentu dapat diindikasikan bahwa terjadi kebocoran (Ozevin & Yalcinkaya, 2013). Dalam penelitian lainnya untuk mendeteksi kebocoran pada pipa dapat dilihat dari tampilan visual *Power Spectral Density* (PSD), dimana jika terjadi kebocoran akan terlihat sinyal yang hilang pada frekuensi tertentu (Khan dkk., 2017). Dalam aplikasinya, untuk memonitoring kondisi pipa menggunakan beberapa *tools* tersebut memerlukan operator yang jeli, teliti dan memahami pergerakan spektrum atau tanda adanya penurunan frekuensi. Sedangkan, menurut Wignjosoebroto tahun 2000 dalam Rahayu dkk (2015) dari segala hal terkait permasalahan manusia dalam berinteraksi dengan mesin, produk ataupun fasilitas kerja lainnya yang dioperasikan, manusia seringkali dianggap sebagai sumber dari permasalahan terjadi seperti terjadinya kecelakaan kerja (*human error*) (Rahayu dkk., 2015). Untuk meminimalisir terjadinya *human error* dalam analisa kebocoran pada pipa untuk skala besar seperti industri perlu ditambahkan adanya model klasifikasi untuk mempermudah operator dalam memonitoring kondisi pipa. Dalam melakukan klasifikasi monitoring yang menggunakan rekaman suara dari sensor AE akan terlebih dahulu dilakukan ekstraksi fitur dari sinyal audio ke bentuk numerik untuk dapat diproses dalam tahapan klasifikasi (Sitti dkk., 2015).

Dalam melakukan ekstraksi pada data akustik salah satunya dapat dilakukan dengan fitur waktu-frekuensi (*time-and frequency features*) yang dinilai memiliki kemampuan untuk mengekstrak ciri sinyal akustik terbaik (Sitti dkk., 2015). Hal tersebut dibuktikan dalam penelitian yang dilakukan oleh Sitti dkk (2015) yang merancang sistem pendeteksi kesalahan suara dalam bahasa inggris. Dihasilkan dengan menggunakan fitur MFCC yang digabungkan dengan metode HMM mampu membedakan suara dengan kemiripan kata dan pelafalan yang cukup tinggi (Sitti dkk., 2015). Dalam beberapa penelitian yang merancang sebuah sistem pengenalan suara, fitur MFCC banyak digunakan untuk melakukan ekstraksi karena hanya sedikit paper yang melaporkan hasil baik menggunakan fitur waktu (Berg-Hansen, 2022). Pada penelitian verifikasi biometrika suara yang dilakukan oleh Putra dan Resmawan (2011) dimana menggunakan MFCC sebagai fitur untuk ekstraksi juga menghasilkan nilai *accuracy* cukup tinggi untuk pengujian sebesar 73,26% (Putra & Resmawan, 2011). Dalam penelitian sebelumnya oleh Aciandra

(2022) melakukan analisa deteksi anomali pada mesin pompa berdasarkan fitur askustik (domain waktu, frekuensi, dan domain waktu-frekuensi) dan *machine learning* yang menggunakan SVM. Pada percobaan menggunakan fitur akustik domain waktu dan frekuensi memiliki *accuracy* yang kurang baik dengan nilai *accuracy* kurang dari 90% sedangkan dengan fitur domain waktu-frekuensi yang menggunakan metode MFCC didapatkan *accuracy* yang cukup tinggi yaitu lebih dari 90% (Aciandra, 2022). Pemodelan yang menggunakan ekstraksi MFCC dengan model SVM paling tinggi memiliki nilai rata-rata *accuracy* (95,32%) dan *f1-score* (92,82%).

Pada penelitian ini akan dilakukan deteksi kebocoran pipa berdasarkan perbedaan 2 (dua) skala kebisingan yaitu laboratorium dan *workshop*, dimana memiliki perbedaan tingkat kebisingan yang cukup signifikan. *Audio file* dikelompokkan berdasarkan variasi jarak *microphone* terhadap kebocoran yang terbagi menjadi 4 diantaranya 20 cm ($\alpha=90^\circ$), 2 m ($\alpha=90^\circ$), 20 cm ($\alpha=30^\circ$), dan *full room*. Dalam setiap dataset *microphone* terdapat 96 data (*leak* dan *no leak*) dengan persentase 80% adalah data *training* dan 20% sisanya adalah data *testing*. Model klasifikasi yang digunakan adalah *Support Vector Machine* (SVM) dan *K-Nearest Neighbor* (KNN). Selanjutnya model akan dievaluasi berdasarkan nilai evaluasi performansi dari dataset jarak setiap *microphone* terhadap lokasi kebocoran (*single sensor*) dan dataset gabungan seluruh *microphone* (*multi sensor*) pada setiap skala kebisingan. Penelitian ini diharapkan mampu memberikan referensi baru terkait deteksi kebocoran pipa dengan menggabungkan metode ekstraksi *Mel-Frequency Cepstral Coefficients* (MFCC) dan diklasifikasikan dengan *machine learning*.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, adapun rumusan masalah dari penelitian ini adalah sebagai berikut :

1. Bagaimana hasil performansi deteksi kebocoran pipa pada skala laboratorium menggunakan metode MFCC dan *machine learning*?
2. Bagaimana hasil performansi deteksi kebocoran pipa pada skala *workshop* menggunakan metode MFCC dan *machine learning*?

1.3 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut :

1. Mengetahui bagaimana hasil performansi deteksi kebocoran pipa pada skala laboratorium menggunakan metode MFCC dan *machine learning*.
2. Mengetahui bagaimana hasil performansi deteksi kebocoran pipa pada skala *workshop* menggunakan metode MFCC dan *machine learning*.

1.4 Manfaat Penelitian

Adapun manfaat dari penelitian adalah sebagai berikut :

1. Menambah pengetahuan serta pemahaman bagi pembaca terkait *machine learning* khususnya pada model *K-Nearest Neighbor* (KNN) dan *Support Vector Machine* (SVM).
2. Menambah pemahaman terkait penerapan *machine learning* dalam melakukan klasifikasi pada 2 keadaan yaitu tidak ada kebocoran (*no leak*) dan terdapat kebocoran (*leak*).
3. Memberikan pengembangan analisa deteksi kebocoran dalam pemeliharaan prediktif.

1.5 Batasan Penelitian

Adapun batasan dari penelitian ini adalah sebagai berikut :

1. Dataset yang digunakan adalah berasal dari *Fraunhofer Institute for Digital Media Technology* IDMT kategori kebocoran pada *tube* dengan kondisi laboratorium dan *workshop*. Link dataset :
<https://www.idmt.fraunhofer.de/en/publications/datasets/isa-compressed-air.html>
2. Model algoritma yang digunakan adalah *Support Vector Machine* (SVM) dan *K-Nearest Neighbor* (KNN) untuk mengklasifikasikan adanya kebocoran (*leak*) atau tidak ada kebocoran (*no leak*).