IMPLEMENTASI SISTEM PERINGATAN KEGAGALAN MESIN ISBM BERBASIS *MACHINE LEARNING* DAN FAILURE MODE AND EFFECT ANALYSIS

Muhammad Raihan Nafis[*1], Septriandi Wirayoga[2], Mohammad Iqbaal Irfan Satria[3]

[1,2,3]Teknik Elektronika, Teknik Elektro, Politeknik Negeri Malang, Indonesia
Email: [1]Yakutunnafis445@gmail.com, [2]yoga.septriandi@polinema.ac.id, [3]Iqbalirfan2306@gmail.com

Nomor Handphone : 085952846190

Abstrak

Tingginya *downtime* pada mesin *Injection Stretch Blow Molding* (ISBM) dapat menyebabkan penurunan efektivitas produksi dan keterlambatan proses *maintenance*. Sistem peringatan konvensional yang digunakan pada industri umumnya masih terbatas dalam memberikan informasi kondisi mesin secara spesifik dan *real-time*. Penelitian ini bertujuan merancang dan mengimplementasikan sistem peringatan kegagalan mesin ISBM berbasis *Machine learning* dan *Failure Mode and Effects Analysis* (FMEA). Sistem menggunakan sensor suhu DS18B20, sensor tekanan WISNER WPT-83G, serta sinyal alarm mesin sebagai parameter utama monitoring. Data sensor diproses menggunakan ESP32 dengan algoritma *K-Nearest Neighbor* (KNN) untuk mengklasifikasikan kondisi mesin menjadi normal, *warning*, dan *danger*. Hasil klasifikasi kemudian dianalisis menggunakan metode FMEA untuk mengidentifikasi potensi kegagalan dan menentukan prioritas penanganan gangguan. Sistem dilengkapi komunikasi LoRa untuk pengiriman data antarperangkat serta SIM800L, DFPlayer, dan *WhatsApp* sebagai media notifikasi otomatis. Hasil pengujian menunjukkan bahwa sensor DS18B20 memiliki rata-rata akurasi sebesar 99,03%, sedangkan sensor WISNER WPT-83G sebesar 97,84% setelah proses kalibrasi. Sistem mampu mendeteksi kondisi abnormal secara *real-time* dan membantu meningkatkan efektivitas proses *maintenance* pada lingkungan industri.

Kata kunci: *Failure Mode and Effects Analysis, Injection Stretch Blow Molding, K-Nearest Neighbor, Machine learning,* Monitoring Industri.

Abstract

High downtime in Injection Stretch Blow Molding (ISBM) machines can reduce production effectiveness and delay maintenance processes. Conventional warning systems used in industry are generally limited in providing specific and real-time machine condition information. This study aims to design and implement an ISBM machine failure warning system based on Machine learning and Failure Mode and Effects Analysis (FMEA). The system utilizes a DS18B20 temperature sensor, a WISNER WPT-83G pressure sensor, and machine alarm signals as the main monitoring parameters. Sensor data are processed using an ESP32 with the K-Nearest Neighbor (KNN) algorithm to classify machine conditions into normal, warning, and danger categories. The classification results are then analyzed using the FMEA method to identify potential failures and determine maintenance priorities. The system is equipped with LoRa communication for inter-device data transmission, as well as SIM800L, DFPlayer, and WhatsApp for automatic notification delivery. Experimental results show that the DS18B20 sensor achieved an average accuracy of 99.03%, while the WISNER WPT-83G sensor achieved 97.84% accuracy after calibration. The system is capable of detecting abnormal conditions in real-time and improving maintenance effectiveness in industrial environments.

Keywords: *Failure Mode and Effects Analysis, Injection Stretch Blow Molding, K-Nearest Neighbor, Machine learning, Industrial Monitoring.*

This work is an open access article and licensed under a Creative Commons Attribution-NonCommercial ShareAlike 4.0 International (CC BY-NC-SA 4.0)

1. PENDAHULUAN

Perkembangan teknologi industri modern mendorong peningkatan kebutuhan terhadap sistem monitoring mesin yang mampu bekerja secara otomatis, cepat, dan *real-time*. Dalam industri manufaktur plastik, khususnya pada mesin *Injection Stretch Blow Molding* (ISBM), keandalan sistem produksi

menjadi faktor penting dalam menjaga stabilitas output produksi [1], [2]. Gangguan kecil pada mesin dapat menyebabkan *downtime* yang berdampak langsung terhadap penurunan efisiensi produksi dan keterlambatan target perusahaan.

Banyak perusahaan manufaktur plastik yang menggunakan mesin *Injection Stretch Blow Molding* dalam proses produksinya. Berdasarkan hasil observasi lapangan, *downtime* mesin masih sering terjadi akibat keterlambatan penanganan gangguan, lambatnya proses diagnosis, serta keterbatasan sistem alarm konvensional yang hanya memberikan indikasi umum tanpa mampu mengidentifikasi sumber permasalahan secara spesifik [2], [3].

Perkembangan teknologi *Internet of Things* (IoT) memungkinkan pengembangan sistem monitoring berbasis sensor yang mampu melakukan pengiriman data secara *real-time* [4], [5]. Selain itu, penerapan *machine learning* dalam bidang *predictive maintenance* dinilai efektif untuk membantu proses klasifikasi kondisi mesin berdasarkan pola data operasional [6]. Salah satu algoritma *machine learning* yang cukup sederhana dan ringan untuk diterapkan pada sistem embedded adalah *K-Nearest Neighbor* (KNN) [7].

Beberapa penelitian sebelumnya telah mengembangkan sistem monitoring berbasis IoT maupun sistem *early warning* menggunakan LoRa dan sensor industri [8], [9]. Penelitian lain juga menunjukkan bahwa metode *Failure Mode and Effects Analysis* (FMEA) mampu digunakan untuk menentukan prioritas penanganan gangguan berdasarkan tingkat risiko kerusakan [10], [11]. Namun sebagian besar penelitian masih berfokus pada parameter tunggal dan belum mengintegrasikan klasifikasi kondisi mesin dengan analisis risiko berbasis FMEA secara terpadu.

Berdasarkan permasalahan tersebut, penelitian ini mengembangkan sistem peringatan kegagalan mesin ISBM berbasis *Machine learning* dan *Failure Mode and Effects Analysis* (FMEA). Sistem dirancang menggunakan sensor suhu DS18B20, sensor tekanan WISNER WPT-83G, dan sinyal alarm mesin sebagai parameter operasional. Data diproses menggunakan ESP32 dengan algoritma KNN untuk menentukan kondisi mesin, kemudian dianalisis menggunakan metode FMEA guna menentukan prioritas penanganan dan jalur notifikasi otomatis kepada *engineer* maupun *supervisor*.

2. METODE PENELITIAN

2.1. Pengumpulan Data

Tahap pengumpulan data dilakukan melalui observasi langsung pada area produksi perusahaan produksi plastik, wawancara dengan engineer dan *supervisor*, serta studi literatur dari jurnal dan penelitian terdahulu yang berkaitan dengan *predictive maintenance*, *machine learning*, dan FMEA [6], [10], [11].

Data operasional mesin diperoleh dari pembacaan sensor suhu DS18B20 [12], sensor tekanan WISNER WPT-83G [13], serta status alarm mesin utama. Parameter tersebut dipilih karena berkaitan langsung dengan kondisi utility dan kestabilan mesin *Injection Stretch Blow Molding*.

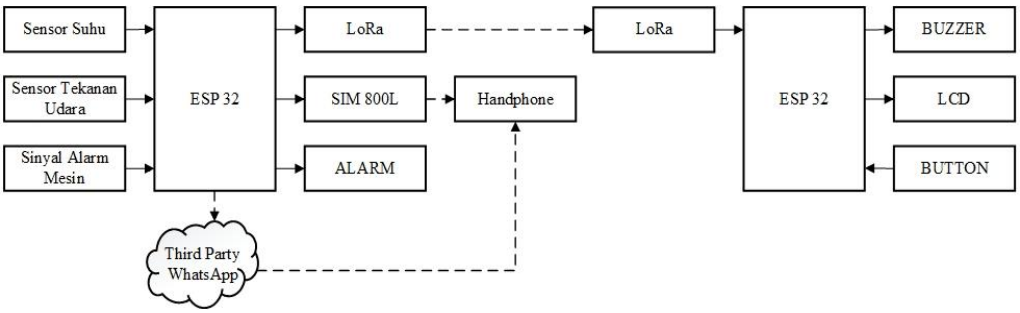
2.2. Perancangan Sistem

Sistem terdiri dari sensor suhu DS18B20 untuk memantau temperatur *chiller water* [12], sensor tekanan WISNER WPT-83G untuk memantau tekanan udara [13], dan sinyal alarm mesin sebagai parameter kondisi operasional. Seluruh data diproses menggunakan ESP32 [14].

Data hasil pembacaan sensor kemudian diklasifikasikan menggunakan algoritma *K-Nearest Neighbor* (KNN) menjadi tiga kategori kondisi yaitu normal, *warning*, dan *danger* [7]. Setelah proses klasifikasi dilakukan, hasil dianalisis menggunakan metode FMEA untuk menentukan tingkat prioritas penanganan berdasarkan nilai *Risk Priority Number* (RPN) [10], [11].

Selain itu, sistem dilengkapi dengan komunikasi LoRa untuk pengiriman data jarak jauh [9], serta modul SIM800L dan *WhatsApp* untuk pengiriman notifikasi otomatis kepada *engineer* maupun *supervisor* [15].

2.3. Diagram Blok Sistem



Gambar 1. Diagram Blok Sistem

Diagram blok sistem pada Gambar 1 menggambarkan arsitektur kerja sistem peringatan kegagalan mesin ISBM yang terdiri dari unit akuisisi data, unit pemrosesan, unit komunikasi, dan unit keluaran peringatan. Pada sisi input, sistem menggunakan tiga parameter utama, yaitu sensor suhu, sensor tekanan udara, dan sinyal alarm mesin. Sensor suhu berfungsi membaca temperatur *chiller* water sebagai indikator kestabilan sistem pendingin, sedangkan sensor tekanan udara digunakan untuk memantau suplai tekanan pneumatik pada mesin. Sinyal alarm mesin digunakan sebagai parameter tambahan untuk mendeteksi kondisi abnormal yang berasal langsung dari sistem kontrol mesin.

Data dari seluruh input dikirimkan menuju ESP32 sebagai unit pemrosesan utama. Pada bagian ini, ESP32 berfungsi untuk membaca data sensor, melakukan pengolahan nilai masukan, menjalankan proses klasifikasi kondisi mesin menggunakan algoritma K-Nearest Neighbor, serta menentukan status sistem berdasarkan kategori normal, *warning*, dan *danger* [7], [14]. Hasil klasifikasi tersebut kemudian digunakan sebagai dasar pengambilan keputusan untuk mengaktifkan jalur peringatan yang sesuai.

Sistem komunikasi dirancang menggunakan dua jalur utama, yaitu komunikasi lokal dan komunikasi jarak jauh. Komunikasi lokal dilakukan melalui modul LoRa yang mengirimkan data dari ESP32 transmitter menuju ESP32 receiver. Pada sisi receiver, data yang diterima digunakan untuk menampilkan informasi kondisi mesin pada LCD, mengaktifkan buzzer sebagai peringatan lokal, serta menerima input dari button sebagai kontrol tambahan pada sistem. Penggunaan LoRa memungkinkan pengiriman data antarunit tanpa bergantung pada jaringan internet, sehingga lebih sesuai untuk lingkungan industri yang membutuhkan komunikasi stabil pada area produksi [9].

Selain komunikasi lokal, sistem juga menggunakan jalur komunikasi eksternal melalui SIM800L dan layanan third party WhatsApp [15]. SIM800L berfungsi mengirimkan notifikasi menuju *handphone* ketika kondisi mesin berada pada kategori warning atau danger. Sementara itu, integrasi *third party WhatsApp* digunakan sebagai media pengiriman informasi gangguan kepada *engineer* maupun *supervisor* secara otomatis. Jalur ini dirancang agar informasi kerusakan tidak hanya diketahui oleh operator di sekitar mesin, tetapi juga dapat diterima oleh pihak terkait meskipun berada di luar area produksi.

Dengan rancangan diagram blok tersebut, sistem tidak hanya berfungsi sebagai alat monitoring, tetapi juga sebagai sistem peringatan bertingkat. Sensor berperan sebagai akuisisi data, ESP32 sebagai pusat pemrosesan dan pengambilan keputusan, LoRa sebagai penghubung antarperangkat, serta SIM800L, *WhatsApp*, buzzer, dan LCD sebagai media penyampaian informasi. Integrasi antarblok ini memungkinkan sistem mendeteksi perubahan kondisi mesin secara *real-time*, memberikan peringatan secara otomatis, dan membantu mempercepat proses penanganan gangguan pada mesin ISBM.

2.4. Algoritma *K-Nearest Neighbor*

K-Nearest Neighbor merupakan algoritma supervised learning yang digunakan untuk klasifikasi berdasarkan jarak terdekat antara data uji dan data latih [7]. Dalam penelitian ini, parameter yang digunakan meliputi suhu *chiller* water, tekanan udara, dan status alarm mesin. Ketiga parameter tersebut dipilih karena mampu merepresentasikan kondisi operasional utama mesin ISBM, baik dari sisi sistem pendingin, sistem pneumatik, maupun kondisi alarm mesin. Perhitungan jarak menggunakan metode *Euclidean Distance* dengan persamaan berikut:

$$D = \sqrt{\sum_{i=1}^{n}(x_i - y_i)} \qquad (1)$$

Keterangan :

D = jarak Euclidean
x = data latih
y = data uji
n = jumlah parameter

Hasil klasifikasi ditentukan berdasarkan mayoritas tetangga terdekat dari nilai k yang digunakan.

2.5. *Failure Mode and Effect Analysis*

Metode FMEA digunakan untuk menentukan tingkat risiko dari kondisi mesin yang telah diklasifikasikan oleh sistem *machine learning* [10], [11]. Penilaian dilakukan berdasarkan tiga parameter utama yaitu Severity (S), Occurrence (O), dan Detection (D).
Perhitungan *Risk Priority Number* dilakukan menggunakan persamaan berikut:

$$RPN = \text{S x O x D} \quad (2)$$

Keterangan :

S = *Severity*
O = *Occurrence*
D = *Detection*

Nilai RPN yang lebih tinggi menunjukkan tingkat risiko yang lebih besar sehingga membutuhkan prioritas penanganan lebih cepat.

3. HASIL DAN PEMBAHASAN

3.1. Implementasi Sistem

Sistem peringatan kegagalan mesin *Injection Stretch Blow Molding* (ISBM) berhasil diimplementasikan menggunakan ESP32 sebagai pusat pemrosesan data. Sistem dirancang untuk memantau kondisi operasional mesin secara *real-time* menggunakan beberapa parameter utama yaitu temperatur *chiller water*, tekanan udara, dan status alarm mesin.

Sensor DS18B20 digunakan untuk memantau suhu *chiller water* karena memiliki tingkat stabilitas pembacaan yang baik dan mudah diintegrasikan dengan ESP32. Selain itu, sensor tekanan WISNER WPT-83G digunakan untuk membaca tekanan udara pada sistem pneumatik mesin ISBM. Parameter alarm mesin digunakan sebagai indikator tambahan untuk mengetahui kondisi abnormal yang terjadi pada mesin.

Data sensor yang diperoleh kemudian diproses menggunakan algoritma *K-Nearest Neighbor* (KNN) untuk menentukan kondisi mesin menjadi tiga kategori yaitu normal, *warning*, dan *danger*. Hasil klasifikasi tersebut selanjutnya dianalisis menggunakan metode *Failure Mode and Effects Analysis* (FMEA) untuk menentukan tingkat prioritas penanganan gangguan.

Selain proses monitoring, sistem juga dilengkapi dengan komunikasi berbasis LoRa untuk pengiriman data antar perangkat. Modul DFPlayer digunakan sebagai alarm suara lokal, sedangkan SIM800L dan *WhatsApp* digunakan untuk mengirimkan notifikasi otomatis kepada *engineer* maupun *supervisor* ketika sistem mendeteksi kondisi abnormal.

Implementasi sistem dilakukan pada lingkungan industri dengan menempatkan sensor pada area utility mesin *Injection Stretch Blow Molding*. Sistem dirancang agar mampu bekerja secara kontinu selama proses produksi berlangsung.

3.2. Pengujian Sensor Suhu

Pengujian sensor DS18B20 dilakukan dengan membandingkan hasil pembacaan sensor terhadap alat ukur referensi berupa termometer digital. Pengujian bertujuan untuk mengetahui tingkat akurasi sensor dalam membaca temperatur *chiller water* pada mesin ISBM.

Tabel 1. Pengujian Sensor Suhu

Pengujian	Hasil Pengujian		Selisih
	DS18B20	Eliwell IC 902	
1	16.8	17	0.2
2	24.7	25	0.3
3	34.6	35	0.4
4	41.6	42	0.4
5	49.5	50	0.5
6	16.1	16	0.1
7	14.1	14	0.1

$$Rata - rata\ Akurasi = \left(\frac{\sum Akurasi\ Setiap\ Pengukuran}{Jumlah\ Pengukuran}\right) x\ 100\% \qquad (3)$$

Perhitungan akurasi dilakukan dengan membandingkan nilai pembacaan DS18B20 terhadap nilai referensi dari Eliwell IC-902. Berdasarkan hasil perhitungan, diperoleh rata-rata akurasi sensor DS18B20 sebesar 99,03%. Nilai tersebut menunjukkan bahwa sensor DS18B20 memiliki tingkat akurasi yang sangat baik dalam membaca suhu. Dengan demikian, sensor DS18B20 layak digunakan sebagai sensor suhu pada sistem monitoring karena hasil pembacaannya sudah mendekati alat ukur referensi.

3.3. Pengujian Sensor Tekanan

Pengujian sensor tekanan WISNER WPT-83G dilakukan dengan membandingkan hasil pembacaan sensor terhadap *pressure gauge* referensi pada sistem pneumatik mesin. Pengujian dilakukan untuk mengetahui tingkat akurasi sensor dalam membaca tekanan udara, dan mengubahnya menjadi persamaan yang digunakan untuk meningkatkan nilai akurasi, berikut persamaan *regresi linier*.

$$y = ax + b \qquad (4)$$

Didapatkan nilai regresi linier sederhana pada persamaan 5 dan 6.

$$Pkoreksi = 0{,}8567\ x\ Pwisner - 1{,}182 \qquad (5)$$

$$Pkoreksi = 0{,}8567\ x\ \left(\left(\frac{Vsensor - 0{,}5}{4{,}0}\right) x\ 40\right) - 1{,}182 \qquad (6)$$

Setelah mendapatkan persamaan regresi linier, maka langsung diterapkan kedalam code ESP 32 untuk meningkatkan nilai akurasi dari Wisner WPT.

Tabel 2 Pengujian Sensor Tekanan

Pengujian	Hasil Pengujian		Selisih
	WISNER WPT	*Pressure gauge*	
1	6.2	6	0.2
2	9.5	10	0.5
3	15.9	16	0.1
4	19.8	20	0.2
5	29.3	30	0.7
6	28.8	29	0.2

Berdasarkan hasil pengujian setelah dilakukan kalibrasi, diperoleh nilai akurasi masing-masing pengujian sebesar 96,67%, 95,00%, 99,38%, 99,00%, 97,67%, dan 99,31% yang dimana dari keseluruhan data tersebut, diperoleh rata-rata akurasi sebesar 97,84%. Hasil ini menunjukkan bahwa persamaan kalibrasi yang digunakan mampu meningkatkan akurasi pembacaan sensor WISNER WPT

3.4. Hasil Klasifikasi *K-Nearest Neighbor*

Pada penelitian ini proses klasifikasi dilakukan menggunakan metode *machine learning* sederhana, yaitu K-Nearest Neighbor (KNN). Metode KNN bekerja dengan cara membandingkan data masukan sensor terhadap data latih yang telah ditentukan sebelumnya. Data latih terdiri dari kombinasi nilai suhu, tekanan dan relay yang mewakili beberapa kondisi mesin, yaitu kondisi normal relay off, suhu terlalu tinggi relay off, suhu terlalu rendah relay off, tekanan terlalu tinggi relay off, dan tekanan terlalu rendah relay off, normal relay on, suhu terlalu tinggi relay on, suhu terlalu rendah relay on, tekanan terlalu tinggi relay on, dan tekanan terlalu rendah relay on.

Pada program yang digunakan, data latih disimpan dalam file training_data.h sebanyak 200 data latih. Setiap kategori memiliki jumlah data yang sama, yaitu 20 data, sehingga pembagian data pada setiap kelas lebih seimbang. Keseimbangan jumlah data ini bertujuan agar proses klasifikasi tidak cenderung mengarah pada salah satu kelas tertentu.

Klasifikasi kondisi mesin dilakukan dengan menghitung jarak antara data masukan sensor dan seluruh data latih menggunakan persamaan Euclid*ean Distance*. Persamaan yang digunakan seperti pada rumus 7.

$$d = \sqrt{(Tinput - Tdata)^2} + (Pinput - Pdata)^2 + W(Rinput - Rdata)^2 \qquad (7)$$

Keterangan :

d: jarak antara data input dan data latih
Tinput : Nilai Suhu dari sensor
Pinput : Nilai Tekanan dari sensor
Rinput : Nilai Alarm mesin dari PLC
Tdata : nilai suhu pada data latih
Pdata : nilai tekanan pada data latih
Rdata : Nilai Alarm mesin dari data latih

Berikut disajikan data training dan klasifikasi kondisi mesin berdasarkan sensor.

Tabel 3 Data Training KNN

No	Label	Kondisi Mesin	Rentang Suhu (°C)	Rentang Tekanan	Status mesin	Jumlah Data
1	0	Normal	18–22	28–31	OFF / 0	20
2	1	Suhu terlalu tinggi	24–28	28–31	OFF / 0	20
3	2	Suhu terlalu rendah	10–14	28–31	OFF / 0	20
4	3	Tekanan terlalu tinggi	18–22	32–35	OFF / 0	20
5	4	Tekanan terlalu rendah	18–22	20–23	OFF / 0	20
6	5	Normal dengan kondisi danger PLC	18–22	28–31	ON / 1	20
7	1	Suhu terlalu tinggi	24–28	28–31	ON / 1	20
8	2	Suhu terlalu rendah	10–14	28–31	ON / 1	20
9	3	Tekanan terlalu tinggi	18–22	32–35	ON / 1	20
10	4	Tekanan terlalu rendah	18–22	20–23	ON / 1	20

Mengacu pada Tabel 3, data training yang digunakan pada metode *K-Nearest Neighbor* terdiri dari tiga parameter utama, yaitu suhu, tekanan, dan status mesin. Parameter suhu digunakan untuk mengetahui kondisi temperatur mesin, parameter tekanan digunakan untuk mengetahui kondisi tekanan pada sistem, sedangkan status mesin dari PLC digunakan untuk mendeteksi adanya sinyal error dari mesin itu sendiri. Data training dibagi ke dalam enam label klasifikasi, yaitu normal, suhu terlalu tinggi, suhu terlalu rendah, tekanan terlalu tinggi, tekanan terlalu rendah, dan normal dengan kondisi danger PLC. Setiap kondisi memiliki 20 data sehingga total data training yang digunakan berjumlah 200 data. Pembagian data tersebut bertujuan agar sistem dapat mengenali pola kondisi mesin berdasarkan kombinasi nilai suhu, tekanan, dan status mesin.

Menggunakan metode KNN, sistem dapat menentukan kondisi mesin berdasarkan kedekatan nilai input terhadap data latih. Apabila suhu dan tekanan masih berada dalam batas normal serta relay tidak aktif, maka sistem akan mengklasifikasikan kondisi mesin sebagai normal. Sebaliknya, apabila terdapat penyimpangan pada suhu, tekanan, atau terdapat sinyal alarm dari PLC, maka sistem akan mengklasifikasikan kondisi tersebut sebagai warning atau danger sesuai dengan kelas data latih terdekat.

3.5. Hasil Pengujian K-Nearest Neighbor

Hasil dari klasifikasi KNN kemudian digunakan sebagai dasar dalam analisis Failure Mode and Effect Analysis (FMEA). Pada tahap ini, setiap kondisi abnormal yang terdeteksi oleh sistem dianalisis sebagai potensi kegagalan pada mesin. Misalnya, kondisi suhu terlalu tinggi dapat mengindikasikan proses pendinginan yang tidak optimal, sedangkan tekanan terlalu rendah dapat mengindikasikan adanya penurunan tekanan pada jalur fluida atau kemungkinan kebocoran. Dengan demikian, integrasi metode KNN dan FMEA memungkinkan sistem tidak hanya menampilkan status kondisi mesin, tetapi juga memberikan dasar identifikasi awal terhadap potensi gangguan yang terjadi, hasil dari perhitungan KNN dapat dilihat pada Tabel 4.

Tabel 4 Pengujian KNN pada sistem

Pengujian	Hasil Pengujian		Alarm Mesin	Hasil KNN
	DS18B20 (°C)	Wisner (Bar)		
1	30.9	29.8	0	Warning
2	21.4	25.8	0	Warning
3	19.2	28.9	0	Normal
4	17.4	29.6	0	Warning
5	31.2	0.5	0	Danger
6	30.6	30.2	1	Warning
7	18.7	29.5	1	Warning
8	18.5	28.9	0	Normal

3.6. Analisis Hubungan Failure Mode and Effect Analysis dan KNN

Metode KNN berfungsi sebagai sistem deteksi kondisi mesin secara otomatis berdasarkan nilai input suhu, tekanan, dan status alarm mesin. Sementara itu, FMEA digunakan sebagai analisis lanjutan untuk mengidentifikasi kemungkinan mode kegagalan, dampak yang ditimbulkan, serta tindakan penanganan yang dapat dilakukan terhadap setiap kondisi abnormal yang terdeteksi. Output klasifikasi KNN berupa status normal, *warning*, dan *danger* menjadi dasar dalam penyusunan analisis FMEA, sehingga sistem tidak hanya mampu memberikan informasi kondisi mesin, tetapi juga mendukung proses identifikasi awal terhadap potensi gangguan. Hubungan antara hasil klasifikasi KNN dan analisis FMEA ditunjukkan pada Tabel 5.

Tabel 5 Pengujian KNN dan FMEA

Status	Kondisi	Failure Mode	Effect	S	O	D	RPN	Tindakan
Warningtt	Suhu terlalu tinggi	Pendinginan tidak optimal	Mesin overheat	5	6	2	60	Periksa *chiller* dan pompa
Warningtr	Suhu terlalu rendah	Suhu kerja tidak stabil	Proses molding terganggu	5	5	2	50	Periksa setting *chiller*
Warningpt	Tekanan terlalu tinggi	Tekanan air berlebih	Risiko kerusakan pipa	5	5	2	50	Periksa valve dan pompa

Status	Kondisi	Failure Mode	Effect	S	O	D	RPN	Tindakan
Warningpr	Tekanan terlalu rendah	Kebocoran atau tekanan turun	Produksi Terganggu	5	6	2	60	Periksa jalur distribusi
Danger	Alarm mesin aktif	Gangguan serius mesin	Produksi berhenti	10	5	2	100	*Maintenance* segera

Berdasarkan Tabel 5, setiap hasil klasifikasi sistem memiliki hubungan dengan potensi kegagalan mesin yang dianalisis menggunakan metode FMEA. Penilaian dilakukan berdasarkan tiga parameter, yaitu *Severity* (S), *Occurrence* (O), dan *Detection* (D), kemudian dihitung menjadi nilai *Risk Priority Number* (RPN). Nilai RPN digunakan untuk menentukan tingkat prioritas penanganan, dimana semakin tinggi nilai RPN maka semakin besar risiko kegagalan yang perlu segera ditangani.

Status warningtt menunjukkan kondisi suhu mesin berada di atas batas normal. Kondisi ini dapat disebabkan oleh pendinginan yang tidak optimal, aliran *chiller* water yang tidak lancar, atau beban kerja mesin yang terlalu tinggi. Dampak dari kondisi tersebut adalah meningkatnya risiko overheat pada mesin, sehingga diperlukan pemeriksaan pada aliran air *chiller*, pompa, dan kestabilan suhu kerja.

Status warningpr menunjukkan tekanan berada di bawah batas normal. Kondisi ini dapat mengindikasikan adanya penurunan tekanan pada jalur distribusi, kemungkinan kebocoran, atau performa pompa yang menurun. Berdasarkan nilai RPN, kondisi ini menjadi salah satu prioritas penanganan karena dapat menyebabkan proses pendinginan tidak maksimal dan mengganggu kestabilan kerja mesin.

Sementara itu, status danger menunjukkan kondisi dengan tingkat risiko tertinggi, yaitu ketika relay alarm dari PLC aktif atau ketika parameter suhu dan tekanan berada jauh dari batas normal. Kondisi ini perlu mendapatkan tindakan pemeriksaan segera oleh operator atau teknisi maintenance untuk mencegah kerusakan yang lebih besar serta mengurangi potensi *downtime* produksi.

Dengan demikian, integrasi KNN dan FMEA pada penelitian ini dilakukan secara berurutan. KNN digunakan untuk mendeteksi dan mengklasifikasikan kondisi mesin berdasarkan parameter suhu, tekanan, dan relay alarm, sedangkan FMEA digunakan untuk menganalisis tingkat risiko dari setiap kondisi abnormal yang terdeteksi. Pendekatan ini membuat sistem tidak hanya mampu memberikan informasi status mesin secara *real-time*, tetapi juga dapat digunakan sebagai dasar pengambilan keputusan dalam tindakan *preventive maintenance*.

4. KESIMPULAN DAN SARAN

4.1 Kesimpulan

Penelitian ini berhasil merancang dan mengimplementasikan sistem peringatan kegagalan mesin *Injection Stretch Blow Molding* berbasis *machine learning* dan *Failure Mode and Effects Analysis* (FMEA). Sistem menggunakan sensor DS18B20, sensor tekanan WISNER WPT-83G, dan sinyal *alarm* mesin untuk memantau kondisi operasional secara *real-time*. Algoritma *K-Nearest Neighbor* berhasil digunakan untuk mengklasifikasikan kondisi mesin menjadi normal, *warning*, dan *danger* berdasarkan data operasional mesin. Metode FMEA berhasil digunakan untuk menentukan prioritas penanganan gangguan melalui perhitungan nilai *Risk Priority Number* (RPN). Selain itu, sistem komunikasi berbasis LoRa, SIM800L, DFPlayer, dan *WhatsApp* mampu memberikan peringatan otomatis kepada pihak terkait secara efektif. Implementasi sistem ini diharapkan mampu meningkatkan efektivitas *maintenance* serta meminimalkan *downtime* produksi pada lingkungan industri.

4.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran untuk pengembangan sistem pada penelitian selanjutnya, antara lain:

1. Algoritma *machine learning* yang digunakan dapat dikembangkan menggunakan metode lain seperti *Random Forest, Support Vector Machine* (SVM), atau *Deep Learning* untuk membandingkan performa klasifikasi terhadap algoritma K-Nearest Neighbor.
2. Sistem komunikasi dapat dikembangkan menggunakan platform Internet of Things berbasis cloud agar monitoring dapat dilakukan secara lebih fleksibel melalui dashboard web maupun aplikasi mobile.
3. Pengujian sistem dapat dilakukan pada lebih banyak jenis mesin industri agar performa sistem terhadap berbagai kondisi operasional dapat dianalisis secara lebih luas.
4. Penelitian selanjutnya dapat menambahkan fitur data logging dan histori kerusakan untuk mendukung implementasi predictive maintenance pada lingkungan industri secara berkelanjutan.
5. Integrasi sistem dengan *Human Machine Interface* (HMI) atau *Supervisory Control and Data Acquisition* (SCADA) dapat dilakukan agar monitoring kondisi mesin menjadi lebih interaktif

5. DAFTAR PUSTAKA

[1] M. D. Susanto, "ANALISIS EFEKTIVITAS MESIN INJECTION MOULDING MENGGUNAKAN METODE OEE DAN FMEA (STUDI KASUS DI PT. CAHAYA BINTANG PLASTINDO)," *Jurnal Sistem Dan Teknik Industri*, Vol. 2, No. 3, pp. 411–421, Apr. 2022.

[2] I. R. Assabil, "Analisis Kerusakan Mesin injection molding pada divisi maintenance di PT jonan Indonesia," *Jurnal SIGMAT Teknik Mesin UNSIKA*, vol. 2, no. 02, pp. 44–52, Dec. 2022. doi:10.35261/sigmat.v2i02.8179

[3] M. F. Anwar, M. Rifa'i, and S. Adhisuwignjo, "Sistem Monitoring dan Alarm Mesin Molding Microplastic Berbasis LabVIEW," *Jurnal Elkolind*, Vol. 8, No. 3, pp. 270–278, Sep. 2021. doi:10.33795/elkolind.v8i3/308

[4] P. Technology, "Cloud-based *real-time* injection mold monitoring system," Plastics Technology, https://www.ptonline.com/products/cloud-based-*real-time*-injection-mold-monitoring-system (Diakses 6 Oktober 2025).

[5] R. D. Pranata, "MONITORING TEMPERATURE *CHILLER* WATER MENGGUNAKAN ANDROID BERBASIS IOT (INTERNET OF THINGS)," Jurnal Sistem Cerdas dan Rekayasa (JSCR), Vol. 4, No. 1, Jun. 2022.

[6] N. Hafidhoh et al., "*Machine learning* Untuk Prediksi kegagalan mesin dalam predictive maintenance system," Jurnal Masyarakat Informatika, vol. 15, no. 1, pp. 56–66, May 2024. doi:10.14710/jmasif.15.1.63641.

[7] D. H. Ramadhani, J. Jumadi, and G. Sandi, "Implementasi algoritma K-nearest neighbors (KNN) Untuk Prediksi Gizi Buruk," SMATIKA JURNAL, vol. 14, no. 02, pp. 326–336, Dec. 2024. doi:10.32664/smatika.v14i02.1360

[8] M. Irfan, A. M. Mappalotteng, and M. Y. Mappeasse3, "Sistem early warning Deteksi Malfungsi Pada motor listrik 3 fasa menggunakan Mikrokontroler Berbasis Lora Terintegrasi scada," JST (Jurnal Sains dan Teknologi), Vol. 14, No. 1, pp. 90–102, May 2025. doi:10.23887/jstundiksha.v14i1.92384

[9] A. R. A. Mulyawan, T. A. D. Kuntjoro, and N. Rachmaningrum, "PERANCANGAN JARINGAN LORA UNTUK MENDUKUNG MONITORING SENSOR DI KAWASAN INDUSTRI NGORO, MOJOKERTO," e-Proceeding of Engineering, vol. 12, no. 2, pp. 2486–2493, Apr. 2025.

[10] M. D. Khairansyah, H. N. Amrullah, and N. F. Qurratuláini, "Penilaian Risiko Kegagalan overhead crane dengan metode failure mode and effect analysis (FMEA) Dan Fishbone Diagram," Jurnal Keselamatan Kesehatan Kerja dan Lingkungan, Vol. 5, No. 2, pp. 93–101, Aug. 2024. doi:10.25077/jk3l.5.2.93-101.2024.

[11] L. S. T. Lestari and P. J. Ginting, "Analisis perawatan Mesin Dengan menggunakan metode failure modes and effects analysis (FMEA)," Jurnal Teknologi dan Manajemen Industri Terapan, vol. 4, no. 3, pp. 825–834, Jul. 2025. doi:10.55826/jtmit.v4i3.1033

[12] A. Siswoyo, "Optimization of temperature sensor selection for incubators: *Real-time* accuracy analysis of DHT22, LM35, and DS18B20 in controlled environment simulations," Internet of Things and Artificial Intelligence Journal, vol. 5, no. 1, Mar. 2025. doi:10.31763/iota.v5i1.877.

[13] B. A. Wibowo and G. Yudharma, "RANCANG BANGUN ALAT UJI KEBOCORAN TUBE SKIN CAREDENGAN SISTEM PERBANDINGAN PRESSURE UDARA (DRYLEAK TEST) MENGGUNAKANARDUINO UNO R3 ATMEGA 328," JUS TEKNO (Jurnal Sains dan Teknologi, vol. 8, no. 2, pp. 21–27, 2024.

[14] K. Kumar, "ESP32-WROOM-32: Features, applications & everything you need to know," ElectronifyIndia, https://www.electronifyindia.com/blogs/news/esp32-wroom-32-features-applications-everything-you-need-to-know (Diakses 6 Oktober 2025).

[15] R. Nurrohim and O. B. Kharisma, "Autonomus call system berbasis ESP32 untuk peringatan Dini Kebakaran Rumah," Jurnal Sistem Cerdas, Vol. 6, No. 2, pp. 134–143, Aug. 2023. doi:10.37396/jsc.v6i2.305