

Implementasi Data Analitik Untuk Penentuan Jadwal Pemeliharaan Mesin Pada Perusahaan Manufaktur Kontinu Skala Besar

Dewanti Anggrahini*, Nani Kurniati, Abiyu Dimas Prasanto, Mohammad Imron,
Muhammad Ainul Yaqin

Departemen Teknik Sistem dan Industri, Fakultas Teknologi Industri dan Rekayasa Sistem, Institut Teknologi Sepuluh Nopember

Abstract

The performance of machine and equipments is one of the critical factors on pursuing World Class Overall Equipment Effectiveness (OEE) target, especially for large-scaled manufacturing companies. They have to determine the most appropriate maintenance strategy; thus, the machines achieve high availability. The company might put some sensors, which it functioned to collect real-time data and information. The data will be processed through data analytics algorithm to identify machine's characteristics, estimate failures, and determine strategic decision related to maintenance schedule in shorter time with higher accuracy. This study proposes a model for implementing data analytics on designing maintenance strategy in a continuous manufacturing through three main stages. Firstly, a model is developed. Then, collect and analyse the data, also model validation as well. At the last stage, finding the right maintenance strategy for its equipments. There are two softwares that are being used, such as MatLab and Phyton. Based on the analysis, it can be concluded that the conceptual model is valid, and the data analytics output has been analysed. This study also finds a condition-based maintenance schedule, which has been expected to be implemented for some other companies with similar characteristics

Keywords: Condition-based, Data Analytics, Continuous Manufacturing, Maintenance, Real Time Based, World Class OEE

Abstrak

Kinerja mesin merupakan faktor kritis yang menentukan tercapainya target World Class Overall Equipment Effectiveness (OEE), khususnya pada industri manufaktur skala besar. Strategi maintenance yang tepat perlu dibuat agar mesin dan peralatan memiliki availability yang tinggi. Salah satu usaha yang dapat dilakukan oleh perusahaan adalah menempatkan peralatan sensor, yang berfungsi sebagai pengumpul data dan informasi pada mesin secara riil (real time based). Data yang diperoleh dari sensor akan diolah dengan metode data analitik untuk mempelajari karakteristik dari mesin yang dijalankan, mengestimasi kegagalan, dan mengambil keputusan strategis terkait maintenance dengan cepat dan akurat. Pada penelitian ini dilakukan pengembangan model implementasi data analitik untuk penyusunan strategi maintenance pada perusahaan manufaktur kontinu. Tahapan yang dilalui dalam penelitian ini adalah pengembangan model, pengumpulan dan pengolahan data serta uji coba model. Tahap akhir dalam penelitian ini adalah penyusunan strategi maintenance yang tepat sesuai dengan karakteristik klaster yang diperoleh. Pengolahan data dalam penelitian ini menggunakan dua software, yaitu MatLab dan Phyton. Berdasarkan analisa hasil yang diperoleh, diketahui bahwa model konseptual yang disusun valid, dan diperoleh hasil perhitungan dengan data analitik. Di akhir penelitian ini juga didapatkan penjadwalan condition-based maintenance, yang diharapkan dapat diimplementasikan untuk perusahaan dengan tipe yang serupa.

Kata kunci: Condition-based, Data Analitik, Kontinu, Pemeliharaan Mesin, Real Time Based, World Class OEE

© 2020 Jurnal SISFO

Histori Artikel : Disubmit 26 November 2020 ; Direvisi 8 Desember 2020; Diterima 15 Desember 2020; Tersedia Online 18 Desember 2020

*Corresponding author

Email address: dewanti@ie.its.ac.id (Dewanti Anggrahini)

<https://doi.org/10.24089/j.sisfo.2020.05.003> (DOI)

1. Pendahuluan

Persaingan di era globalisasi ini mendorong setiap perusahaan untuk melakukan perbaikan secara berkelanjutan. Bagi sebagian besar perusahaan, terutama perusahaan berskala besar, adalah mendapatkan status sebagai *World Class Manufacturing*. Pada [1] disebutkan bahwa nilai target *World Class Overall Equipment Effectiveness* (OEE) adalah sebesar 85%. Standar nilai tersebut dihitung dari tiga hal, yaitu kesiapan mesin (*availability*), performansi (*performance*), dan kualitas (*quality*). *Availability* merupakan nilai rasio dari panjang waktu mesin dioperasikan setelah dikurangi dengan waktu set up dan *breakdown*, dengan waktu mesin yang direncanakan. Performansi mesin dan peralatan dapat dihitung dari banyaknya unit produk yang dihasilkan pada waktu yang tersedia, sedangkan nilai *quality* diperoleh dengan membandingkan jumlah produk baik dengan total unit yang diproduksi. Mengacu pada kriteria penilaian tersebut, diketahui bahwa kinerja mesin merupakan faktor kritis yang menentukan tercapainya target OEE yang tinggi. Untuk mencapai kinerja mesin yang lebih tinggi, perusahaan perlu menentukan strategi pemeliharaan mesin dan peralatan yang tepat.

Sistem *maintenance* yang selama ini banyak diterapkan oleh perusahaan adalah berdasarkan terjadinya kegagalan mesin atau yang lebih sering diketahui sebagai *corrective maintenance*. Setelah dilakukan diskusi dengan beberapa perusahaan manufaktur, diketahui bahwa penerapan sistem tersebut tidak selalu akurat dalam mengatasi permasalahan *breakdown* mesin di lantai produksi. Kegagalan atau *breakdown* mesin dapat terjadi secara acak dalam rentang waktu tertentu dan seringkali tidak dapat ditangani secara optimal melalui sistem *corrective maintenance*. Di sisi lain, banyak juga perusahaan yang menerapkan sistem pemeliharaan pencegahan (*preventive maintenance*) dengan mengestimasi waktu terjadinya kerusakan. Dalam penentuan strategi *preventive maintenance* seringkali ditemukan ketidakakuratan karena adanya eror pada data. Berdasarkan analisa tersebut, diketahui bahwa untuk merancang strategi pemeliharaan yang optimal diperlukan sekumpulan data yang akurat.

Upaya yang dapat dilakukan oleh perusahaan adalah dengan menempatkan peralatan sensor. Sensor tersebut akan berfungsi sebagai pengumpul data dan informasi pada mesin secara riil (*real time based*) dan sangat cepat. Data yang diperoleh dari sensor akan diolah untuk mempelajari karakteristik dari mesin yang dijalankan dan mengestimasi waktu terjadinya kegagalan. Pendekatan ini disebut sebagai data analitik. Hal ini sesuai dengan [2] yang menyatakan bahwa dengan menggunakan data analitik perusahaan dapat menarik kesimpulan, membuat prediksi dan mengambil keputusan strategis.

Beberapa penelitian terkait data analitik untuk menyelesaikan permasalahan *maintenance* telah dikembangkan sebelumnya. [3] melakukan *forecasting* terhadap *time to failure* mesin dengan menggunakan metode *Support Vector Regression* (SVR). Dari penelitian [3] diperoleh kesimpulan bahwa SVR mampu memberikan hasil yang cepat dan akurat dalam menangani *time series data*. [4] meneliti tentang manajemen perawatan mesin industri dengan metode *Artificial Neural Network* (ANN) di sebuah perusahaan proses, untuk menentukan karakteristik kerusakan mesin. Metode ANN ini juga digunakan dalam penelitian [5] dan [6]. [5] Mengaplikasikan ANN untuk *condition based predictive maintenance* dengan obyek industri otomotif, sedangkan [6] menerapkan ANN untuk memprediksi kegagalan motor. Berdasarkan [4], [5], dan [6] diketahui bahwa ANN memberikan performansi terbaik dengan nilai *Root Mean Square Error* (RMSE) terkecil bila dibandingkan dengan *Support Vector Machine* (SVM), *Random Forest* (RF) dan *Regression Tree* (RT) Method.

Selain itu, [7] mengembangkan penelitian dengan menggunakan *wireless vibration* untuk memantau asset dan mendeteksi kegagalan dini pada alat. Metode ini dapat membantu mengoptimalkan perencanaan pemeliharaan dan mengambil Tindakan akuisisi data menggunakan *condition-based maintenance*. Peneliti lain yaitu [8] menggunakan metode data mining menggunakan data supervisi untuk memprediksi beban energi dan *fault detection and diagnosis* (FDD). Pada penelitian yang dilakukan [9], algoritma k-means digunakan untuk menentukan pusat pengelompokan awal, memilih data sampel yang bersifat anomali, dan menghasilkan pengelompokan data. [9] menyimpulkan bahwa metode k-means dapat menjadi solusi optimal global, varians *intra-cluster* berkurang sebesar 15.5% apabila dibandingkan dengan metode yang lain dalam *clustering*. [10] mengembangkan arsitektur yang mengintegrasikan beberapa teknik *data mining* untuk dapat mengestraksi informasi penting pada *decision trees*. Fitur tersebut memiliki akurasi yang tinggi untuk memprediksi *remaining useful life* (RUL) dan menentukan tindakan pemeliharaan komponen. Model baru untuk mengintegrasikan metode *bin packing* dalam menyelesaikan masalah jadwal penggantian mesin dikembangkan dalam [11]. Pada metode ini mengkombinasikan metode *time-based replacement* (TBR), *flexible time-based replacement* (FTBR) dan algoritma *bee colony* (ABC). Pada tahun 2020, [12] mengembangkan model berbasis regresi *non-linear* untuk agregasi data setiap node sensor ke kepala klaster untuk penggabungan data dan menghasilkan fungsi *non-linear* tunggal, sedangkan [13] mengimplementasikan desain modularitas untuk membantu kegiatan *preventive maintenance* pada komponen mesin menjadi sebuah sistem pemeliharaan. Namun belum ada penelitian yang dikembangkan untuk menyusun kerangka penentuan strategi pemeliharaan mesin dengan menggunakan pendekatan data analitik, khususnya untuk industri manufaktur kontinu.

2. Tinjauan Pustaka

Pada bagian ini, tinjauan Pustaka terdiri dari dua kerangka berpikir penyelesaian masalah, yaitu sistem pemeliharaan dan data analitik.

2.1. Sistem Pemeliharaan

Pemeliharaan (*maintenance*) mesin dan peralatan merupakan serangkaian aktivitas yang dilakukan untuk menjaga performansi dan menghindari terjadinya kegagalan, yang dapat merugikan sistem. [14] mendefinisikan pemeliharaan mesin menjadi dua kategori yaitu *preventive* dan *corrective maintenance*. Pemeliharaan *preventif* merupakan aktivitas memelihara mesin dan peralatan dengan melihat kriteria kondisi sistem [14]. *Maintenance* ini dilakukan berdasarkan prediksi periode pemeliharaan, dengan tujuan untuk mengurangi peluang terjadinya kegagalan dan penurunan fungsi saat mesin dijalankan. *Preventive maintenance* ini dapat dilakukan dengan dua cara, yaitu *condition-based maintenance* dan *predetermined maintenance*. *Condition-based maintenance* merupakan pemeliharaan terjadwal, dilakukan secara terus menerus atau berdasarkan kebutuhan, sedangkan *predetermined maintenance* dilakukan berdasarkan prediksi kegagalan mesin saja. Sebaliknya, *corrective maintenance* didefinisikan sebagai pemeliharaan yang dilakukan telah terjadi kegagalan sistem [14]. Di dalam sistem pemeliharaan ini menggunakan *run to failure* sehingga dapat dilakukan penanganan untuk memperbaiki kondisi sistem seperti kondisi awal.

2.2. Data Analitik

Data analitik adalah ilmu untuk mengintegrasikan data yang heterogen dari berbagai sumber, menarik kesimpulan dan membuat prediksi untuk keperluan penyusunan inovasi, peningkatan keunggulan bisnis dan pembuatan keputusan strategis [2]. Di dalam data analitik, terdapat proses *data mining*. *Data mining* merupakan proses spesifik untuk menemukan keilmuan dan pengetahuan yang diamati, seperti pola, hubungan keterkaitan, perubahan, kekhasan dari data dan struktur dari data di dalam database dan penyimpanan informasi. [15] menyebutkan ada empat proses dalam data mining, yaitu *data clustering*, klasifikasi data, regresi atau estimasi dan asosiasi data. *Data mining* dapat diimplementasikan di banyak kasus dalam industri, seperti pada rantai produksi dan pemeliharaan mesin serta peralatan; atau aktivitas dan kebutuhan sehari-hari. Berdasarkan [15] diketahui bahwa teknik *data mining* sangat membantu dalam penyelesaian masalah dan memiliki karakteristik sebagai berikut:

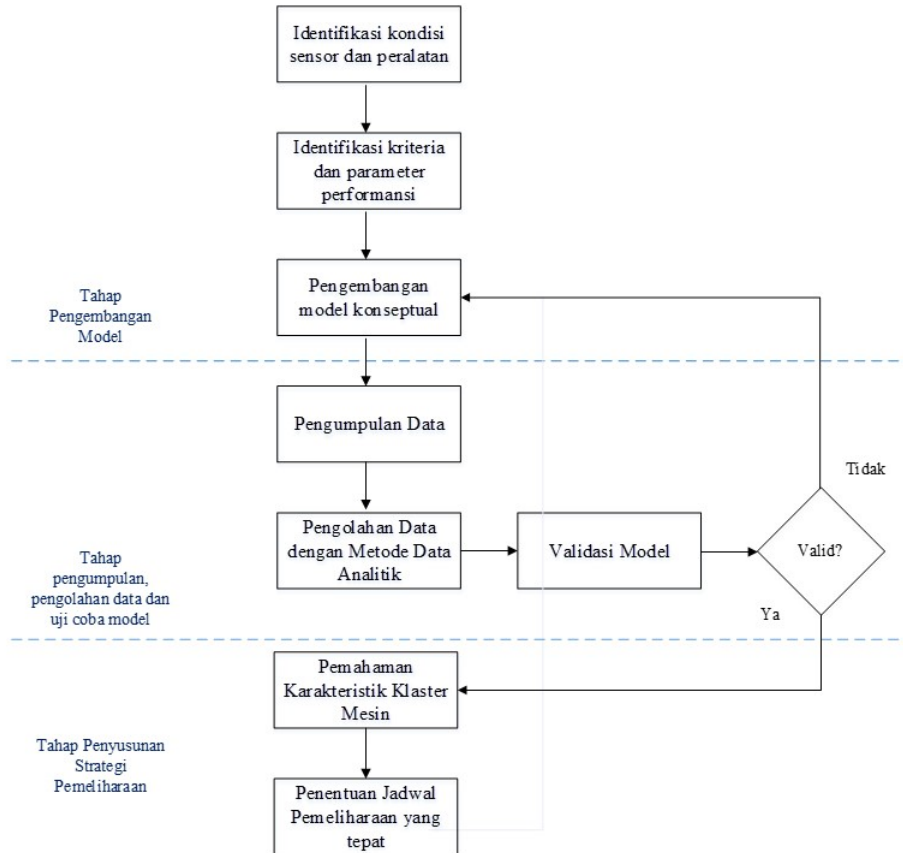
1. Membutuhkan keputusan berbasis pengetahuan, data dan informasi.
2. Memiliki lingkungan yang dinamis.
3. Metode yang ada saat ini tergolong dalam *sub-optimal*.
4. Terdapat data yang dapat diakses, memadai dan relevan.
5. Memberikan keuntungan dalam pengambilan keputusan yang tepat dan cepat.

3. Metodologi

Berdasarkan tujuan penelitian untuk menghasilkan sebuah model penyusunan strategi pemeliharaan mesin dan peralatan yang menggunakan data analitik, maka pendekatan yang digunakan adalah studi kasus kuantitatif pada sebuah perusahaan manufaktur yang menjalankan proses (*continuous manufacturing*). Penelitian ini terdiri dari tiga tahapan, yaitu tahap pengembangan model, tahap pengumpulan data dan uji coba model, serta tahap penyusunan strategi pemeliharaan berdasarkan analisa model (Gambar 1).

Sebelum dilakukan pengembangan model, pada penelitian ini dilakukan kajian terhadap beberapa model *data mining* yang dapat digunakan untuk mengolah data sensor. Pada tahap pengembangan model ini juga dilakukan identifikasi kondisi sensor dan peralatan, identifikasi kriteria dan parameter performansi, serta pengembangan model konseptual terhadap objek kajian yang telah ditentukan. Tahap pengembangan model dilakukan dengan menggunakan kajian literatur serta diskusi dengan praktisi dan industri, yang menghasilkan model implementasi data analitik untuk penentuan strategi pemeliharaan yang mengakomodir kondisi dan perubahan yang terjadi di rantai produksi.

Tahap kedua adalah tahap pengumpulan, pengolahan data dan uji coba model. Model yang telah disusun pada tahapan sebelumnya, kemudian diuji cobakan pada perusahaan manufaktur kontinu skala besar. Model diuji cobakan melalui beberapa sub-tahapan seperti memastikan sensor bekerja dengan baik, pengumpulan data sensor dalam satuan menit, kemudian pengolahan dan analisis data. Perusahaan yang digunakan sebagai studi kasus ini adalah sebuah perusahaan skala besar dengan kapasitas produksi lebih dari 2.000.000 (dua juta) ton per tahun. Sebagian besar hasil produksi perusahaan ini didistribusikan di dalam negeri dan sisanya diekspor ke beberapa negara, terutama di wilayah Asia. Di perusahaan ini terdapat tiga proses, dimana yang diamati adalah dua proses utama. Pada proses I, terdapat 1



Gambar 1. Bagan Alir Penelitian

(satu) mesin dengan 4 (empat) peralatan kritis yang didalamnya diimplementasikan 5 (lima) buah sensor; sedangkan pada proses II terdapat 1 (satu) mesin dengan 7 (tujuh) peralatan dengan 7 (tujuh) buah sensor. Pada penelitian ini, dibatasi hanya menggunakan data dari 1 peralatan yang terdiri 7 (tujuh) buah sensor. Sensor-sensor ini telah dioperasikan lebih dari 1 (satu) tahun.

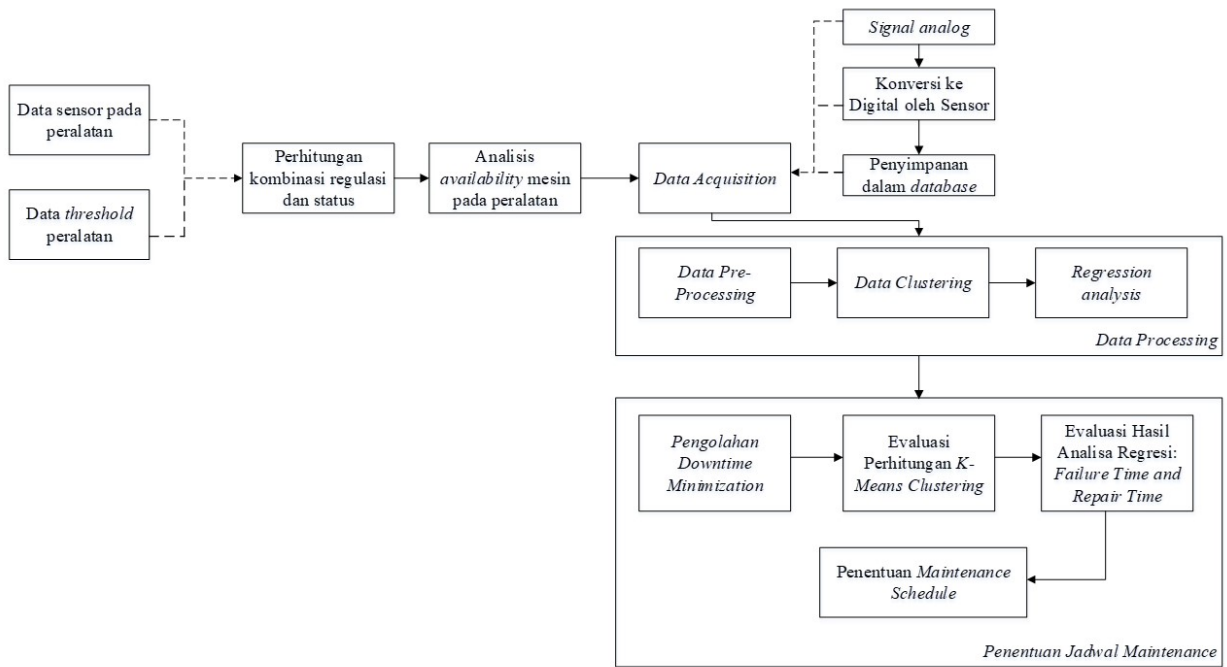
Pada tahap pengumpulan, pengolahan dan uji coba model ini digunakan metode data analitik. Metode yang digunakan pada klusterisasi data adalah *K-Means Clustering* dengan perhitungan *Elbow Method*, dengan melihat *Sum of Square Error*, dan *Shilloutte Index*. Setelah itu dilakukan analisa regresi dengan menggunakan metode *non-linear regression*. Pada tahap ini data yang berjumlah sangat besar diolah dan dianalisa untuk mendapatkan jumlah kluster yang optimal.

Hasil dari tahapan kedua adalah berupa input bagi proses penyusunan jadwal pemeliharaan mesin. Dalam tahap terakhir ini, peneliti mencoba menyusun langkah yang dapat dilakukan untuk melakukan pemeliharaan sesuai dengan data waktu riil yang telah diperoleh. Metode yang digunakan dalam penentuan ini adalah *CIRP (constant interval replacement policy)*. Dengan penggunaan data tersebut, diharapkan dapat meningkatkan akurasi penyusunan strategi dan langkah yang akan dilakukan dapat lebih tepat dan sesuai dengan kondisi dari mesin yang ada.

4. Hasil dan Pembahasan

Pada tahap pertama adalah pengembangan model. Pada tapan ini dilakukan kajian literatur, serta berdiskusi dengan operator di perusahaan untuk dapat mengidentifikasi kondisi sensor dan peralatan serta identifikasi kriteria serta parameter performansi. Luaran dari dua tahapan tersebut akan digunakan dalam proses pengembangan model konseptual.

Pada tahap ini model yang dihasilkan bersifat generik, dimana akan dapat diimplementasikan pada peralatan yang lain. Model tersusun dari proses perhitungan kombinasi regulasi dan status peralatan, berdasarkan data sensor dan data *threshold* pada peralatan. Setelah itu hasil dari perhitungan akan digunakan untuk melakukan analisis *availability* mesin. Sementara pada proses data analitik, model tersusun atas dua tahap besar yaitu *data acquisition* dan *data*

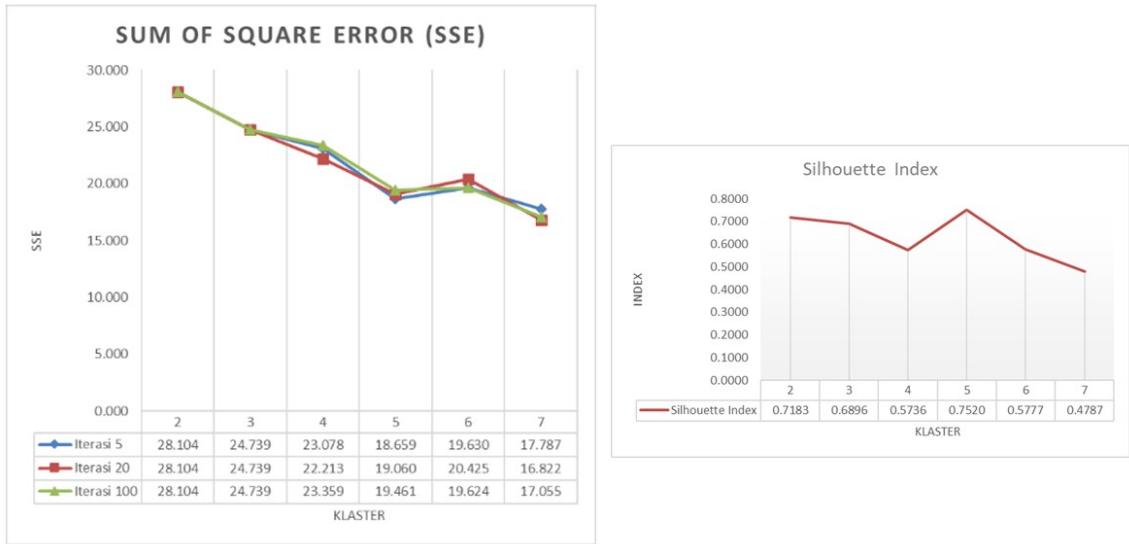


Gambar 2. Model Implementasi Data Analitik Untuk Penyusunan Strategi Pemeliharaan


processing. Pada *data acquisition* adalah tahap pengumpulan data berupa signal analog yang diterima oleh sensor dan disimpan dalam database. Signal analog ini merupakan bentuk data yang merepresentasikan kondisi dan perilaku mesin dan peralatan yang diamati. Sedangkan sensor berfungsi untuk mengubah *signal* analog tersebut menjadi digital yang akan disimpan di dalam database, dan dengan bentuk yang dapat memudahkan pengolahan data tersebut. Selanjutnya, luaran dari *data acquisition* akan diolah pada tahapan *data processing*. Terdapat tiga sub-tahapan pada *data processing*, yaitu *data pre-processing*, *data clustering* dan analisa regresi. *Data processing* merupakan proses mengolah data untuk memperoleh informasi yang dibutuhkan. Pada tahapan ini digunakan teknik *data mining* untuk mengetahui jenis *breakdown* yang terjadi, pengelompokan jenis *breakdown*, dan melakukan prediksi terhadap terjadinya *breakdown* mesin dan peralatan. Luaran dari data processing ini digunakan untuk menyusun strategi pemeliharaan yang tepat. Model ini kemudian diuji coba pada penelitian ini. Model penentuan strategi pemeliharaan dengan menggunakan pendekatan data *analytics* digambarkan pada Gambar 2.

Setelah model penyusunan strategi pemeliharaan diperoleh, pada tahap selanjutnya adalah pengumpulan dan pengolahan data data serta uji coba model. Pada penelitian ini diperoleh data sensor dengan periode 3 (tiga) tahun, dengan interval waktu 60 detik. Data yang diambil berupa data kontinu, dengan total data mendekati 35.000 data. Pada setiap data sensor memiliki *threshold* yang digunakan untuk mengetahui *current condition* dari setiap peralatan yang diuji. Hasil integrasi dari tiap jenis peralatan kemudian dibandingkan dengan *equipment regulation*. Pada penelitian ini, diperoleh 128 regulasi *equipment regulation*, yang terdiri dari 5 regulasi ketika data sensor mendeteksi peralatan dalam kondisi bekerja (*running*) dan 123 regulasi ketika data sensor mendeteksi peralatan dalam kondisi *breakdown*. Dari perhitungan ini akan diperoleh waktu terjadinya *breakdown* dan waktu Kembali beroperasi, yang kemudian digunakan untuk menghitung *availability* mesin, dengan nilai *time to failure* (TTF) dan *time to repair* (TTR). Dalam penelitian ini, diketahui rata-rata *availability* tiap periode sebesar 0.85 atau 85%. Dikutip dari [1] *World Class Overall Equipment Effectiveness* (OEE) terdiri adalah *availability*, *performance*, dan *quality*. Untuk dapat mencapai target *World Class OEE* sebesar 85%, diperlukan nilai faktor *availability* sebesar 90%, *performance* sebesar 95%, dan *quality* sebesar 99%. Bila dibandingkan dengan standar *World Class Manufacturing* yaitu 90%, maka dapat disimpulkan *availability* peralatan masih perlu ditingkatkan.

Pada tahap *proceesing*, terdiri dari *data pre-processing*, klasterisasi data, analisa regresi. Pada tahapan data pre-processing digunakan teknik *data scaling*, sedangkan *data clustering*, menggunakan algoritma k-means *clustering*. Pengolahan data ini menggunakan dua software, yaitu MatLab dan Phytion. Perbandingan hasil perhitungan SSE dan *Silhouette Index* ditunjukkan pada Gambar 3 dan 4. Dua perangkat lunak ini menghasilkan luaran yang sedikit



Gambar 3. Hasil Perhitungan SSE dan *Silhouette Index* Menggunakan Software MatLab



Gambar 4. Hasil Perhitungan SSE dan *Silhouette Index* Menggunakan Software Python

Tabel 1. Perbandingan Hasil Pengolahan Data

Kriteria Perbandingan	Software	
	Matlab	Phyton
Jumlah Iterasi	3	3
Klaster optimum berdasarkan <i>Elbow Method</i> (nilai <i>Sum of Square Error</i>)	5	8
Klaster optimum berdasarkan <i>Silhouette Index</i>	5	8

berbeda. Perbandingan luaran dari dua software seperti ditampilkan pada Tabel 1.

Berdasarkan hasil pengolahan data pada software MatLab, diketahui bahwa titik dari jumlah kluster 4 ke jumlah kluster 5 mengalami penurunan nilai SSE lebih besar dari jumlah kluster lainnya. Analisa ini ditunjang dengan metode Elbow dengan melihat bentuknya sudut siku pada titik jumlah kluster 5. Dari perhitungan tersebut, juga diperoleh hasil bahwa terdapat 5 kluster kondisi *breakdown* berdasarkan perhitungan TTF dan TTR. Kluster 3 merupakan kluster data sensor yang mengindikasikan tingkat *breakdown* yang berat, kluster 4 merupakan kluster data sensor yang mengindikasikan tingkat *breakdown* ringan, sedangkan kluster 1, 2 dan 5 merupakan kluster data sensor yang mengindikasikan tingkat *breakdown* sedang. Tingkat *breakdown* dalam penelitian ini diidentifikasi berdasarkan frekuensi terjadinya kegagalan mesin selama proses berjalan dimana semakin tinggi angka terjadinya *breakdown*, maka semakin tinggi nilai downtime dan semakin rendahnya nilai *availability* mesin dan peralatan.

Dari hasil pengolahan data dengan software Phyton, diketahui bahwa nilai TTF dan TTR berturut – turut adalah 1, 5 dan 108, 5. Untuk kluster 1, 3, 4, 6 dan 8 merupakan kluster dengan tingkat kerusakan sedang. Untuk kluster sedang dengan tingkatan tinggi adalah kluster 4 dan 8 dengan nilai TTF dan TTR berturut turut adalah 176,28 ; 5,4 dan 165,2 ; 6,8. Untuk kluster sedang dengan tingkatan sedang adalah kluster 6 dengan TTF dan TTR adalah 27 dan 405. Sedangkan untuk tingkatan sedang adalah kluster 1 dan 3 dengan nilai TTF dan TTR adalah 102,7 ; 15,89 dan 103,5 ; 15,893. Dari tahapan ini dapat disimpulkan dimungkinkan terjadi perbedaan jumlah kluster dari dua software yang berbeda. Untuk itu, perlu ada langkah lanjutan untuk menentukan karakteristik masing-masing kluster. Dalam penelitian ini, penentuan tersebut dilakukan dengan berdiskusi dengan pihak perusahaan sekaligus mencermati karakteristik pada tiap kluster. Namun secara garis besar, dapat disimpulkan bahwa langkah pada model ini valid untuk dilakukan.

Pada tahap analisa regresi, luaran dari software MatLab ini kemudian diolah dengan menggunakan *non-linear regression*. Model *non-linear regression* digunakan untuk memperoleh prediksi TTF dan TTR. Hasil prediksi menghasilkan parameter berupa distribusi Weibull. Dalam distribusi ini diketahui parameter Beta, parameter Eta, dan parameter Gamma. Dengan menggunakan data yang ada, dilakukan perhitungan *root mean square error* (RMSE) untuk mengetahui seberapa baik hasil regresi tersebut. Berdasarkan hasil analisa menunjukkan kluster 3 masih menjadi kluster data sensor yang mengindikasikan tingkat *breakdown* berat, dengan nilai rata-rata TTF dan TTR tertinggi yaitu 372,93 jam dan 355,42 jam. Sedangkan kluster 4 juga masih menjadi kluster data sensor yang mengindikasikan tingkat *breakdown* ringan. Dimana nilai rata-rata TTF dan TTR yang terendah yaitu 134,7 jam dan 1 jam. Sedangkan kluster 1, kluster 2 dan kluster 5 masih tetap menjadi kluster data sensor yang mengindikasikan tingkat *breakdown* sedang. Sedangkan dengan software Phyton, hasil prediksi menggunakan model *non-linear regression* dilakukan dengan dua jenis parameter berbeda yaitu pertama TTF dan TTR, kedua TTR dan *reliability*. Berdasarkan nilai RMSE yang semakin kecil maka hasil prediksi sudah baik dan mendekati akurat. Parameter TTF dan TTR dilakukan pada 8 kluster yang terbentuk, diperoleh kluster 1, 2, 3, dan 4 menunjukkan hasil prediksi kurang baik, kluster 6 dan 8 cukup baik, dan kluster 5 sudah baik. Sedangkan untuk parameter TTR dan *reliability* dilakukan pada 5 kluster yang terbentuk, diperoleh keseluruhan kluster menunjukkan hasil prediksi yang sudah baik dan mendekati akurat.

Dari hasil analisa regresi luaran software MatLab, perancangan strategi pemeliharaan bertujuan untuk meminimalkan *downtime*. Metode yang digunakan dalam penelitian ini adalah the *Constant Interval Replacement Policy* (CIRP) dengan cara perancangan jadwal *maintenance* berdasarkan interval waktu. Penentuan jadwal optimum ini diperoleh dari nilai CIRP minimum, yang dipengaruhi oleh *failure rate* dan *repair rate*. Berdasarkan hasil analisa diperoleh bahwa jadwal *maintenance* yang optimum untuk kluster 1, 2, 3, 4 dan 5 berturut-turut adalah 800 jam, 2100 jam, 205 jam, 8 jam, dan 400 jam. Sedangkan luaran dari software Phyton diketahui bahwa jadwal *maintenance* optimum yaitu kluster 1 dilakukan setiap 60 jam, kluster 2 dilakukan setiap 100 jam, kluster 3 dilakukan setiap 100 jam, kluster 4 dilakukan setiap 180 jam, kluster 5 dilakukan setiap 60 jam, kluster 6 dilakukan setiap 100 jam, kluster 7 dilakukan setiap 60 jam, dan kluster 8 dilakukan setiap 60 jam. Hasil jadwal *maintenance* menggunakan metode CIRP berdasarkan nilai TTR dan *reliability* diperoleh 5 kluster dengan jadwal *maintenance* optimum yaitu kluster 1 dilakukan setiap 150 jam, kluster 2 dilakukan setiap 150 jam, kluster 3 dilakukan setiap 400 jam, kluster 4 dilakukan setiap 400 jam, dan kluster 5 dilakukan setiap 250 jam. Perbedaan hasil perhitungan ini dapat terjadi ketika ada satu saja data yang berbeda karena kesalahan (eror) input data ataupun hal lain saat pengolahan data. Untuk itu, sangat

diperlukan kehati-hatian dan akurasi tinggi pada proses *pre-processing*, dan *processing* data. Untuk bagian analisa, luaran pengolahan data dari software digunakan sebagai landasan dalam melakukan analisa dalam identifikasi karakteristik masing-masing kluster sebelum ditentukan jadwal pemeliharaan yang tepat. Selain itu, dalam penelitian ini diperlukan adanya komunikasi dan diskusi dengan operator di perusahaan terkait dengan pemahaman karakteristik dan pemeliharaan mesin, termasuk pengaruh dari umur pakai mesin dan juga peralatan sensor yang digunakan.

5. Kesimpulan

Berdasarkan hasil analisa, pada bagian ini akan diuraikan simpulan dan saran yang dapat diberikan untuk dilakukan pada penelitian selanjutnya.

5.1. Simpulan

Simpulan yang diperoleh dari penelitian ini adalah:

1. Model yang diusulkan dapat digunakan untuk menentukan jadwal pemeliharaan, sebagai bagian dari strategi *maintenance* mesin dan peralatan.
2. Terdapat perbedaan hasil perhitungan kluster dari dua *software* yang digunakan. Untuk itu, perlu dilakukan langkah lanjutan dalam memahami karakteristik mesin dan peralatan dan kemudian disusun *maintenance schedule* yang tepat.
3. Jadwal *maintenance* yang optimum dapat ditentukan berdasarkan luaran analisa regresi *non-linear* dengan menggunakan metode CIRP.

5.2. Saran

Saran yang diusulkan untuk penelitian selanjutnya adalah:

1. Dapat menggunakan data sensor tanpa intervensi dari sistem atau operator, agar diperoleh data yang lebih akurat.
2. Data sensor yang digunakan akan lebih akurat bila menggunakan interval waktu yang lebih pendek.
3. Penelitian selanjutnya dapat dilakukan dengan metode klasifikasi dan regresi linear untuk condition-based maintenance.

References

- [1] Vorne, World-Class OEE (Accessed: 2020-02-28). URL <https://www.oeo.com/world-class-oeo.html>
- [2] V. N. Gudivada, Chapter 2 - Data Analytics: Fundamentals, Data Analytics for Intelligent Transportation Systems, Elsevier, 2017. doi:10.1016/B978-0-12-809715-1.00002-X.
- [3] M. das Chagas Moura, E. Zio, I. D. Lins, E. Droguett, Failure and reliability prediction by support vector machines regression of time series data, Reliability Engineering and System Safety 96 (11) (2011) 1527–1534. doi:10.1016/j.ress.2011.06.006.
- [4] A. Suyuti, Z. Tahir, F. Alhari, M. Rafirin, Analisis Manajemen Perawatan Mesin Industri dengan Menggunakan Jaringan Saraf Tiruan Feed Forward-Back Propagation (Studi Kasus PT. Semen Bosowa Maros), in: Prosiding Seminar Nasional Teknik Informatika (SNATIKA) : IT for a Brighter Future, 2013, pp. 15–20.
- [5] J. Krenek, K. Kuca, P. Blazek, O. Krejcar, D. Jun, Application of Artificial Neural Networks in Condition Based Predictive Maintenance, Recent Developments in Intelligent Information and Database Systems, Springer, Cham, 2016. doi:10.1007/978-3-319-31277-4.
- [6] G. S. Sampaio, A. R. de Aguiar Vallim Filho, L. S. da Silva, L. A. da Silva, Prediction of motor failure time using an artificial neural network, Sensors 19 (19) (2019) 4342. doi:10.3390/s19194342.
- [7] B. Myhr, S. Petersen, R. Ugarelli, Using wireless vibration monitoring to enable condition-based maintenance of rotating machinery in the water and wastewater industries, Procedia Engineering 89 (2014) 1397–1403. doi:10.1016/j.proeng.2014.11.465.
- [8] Y. Zhao, C. Zhang, Y. Zhang, Z. Wang, J. Li, A review of data mining technologies in building energy systems: Load prediction, pattern identification, fault detection and diagnosis, Energy and Built Environment 1 (2) (2020) 149–164. doi:10.1016/j.enbenv.2019.11.003.
- [9] W. Yang, H. Long, L. Ma, H. Sun, Research on clustering method based on weighted distance density and k-means, Procedia Computer Science 166 (2020) 507–511. doi:10.1016/j.procs.2020.02.056.
- [10] K. Gandhi, B. Schmidt, A. H. Ng, Towards data mining based decision support in manufacturing maintenance, in: Procedia CIRP, 2018, pp. 261–265. doi:10.1016/j.procir.2018.03.076.
- [11] S. Ozcan, F. Simsir, A new model based on Artificial Bee Colony algorithm for preventive maintenance with replacement scheduling in continuous production lines, Engineering Science and Technology, an International Journal 22 (6) (2019) 1175–1186. doi:10.1016/j.jestech.2019.08.003.
- [12] A. L. Sreenivasulu, P. C. Reddy, NLDA non-linear regression model for preserving data privacy in wireless sensor networks, Digital Communications and Networks 6 (1) (2020) 101–107. doi:10.1016/j.dcan.2019.01.004.
- [13] N. T. Putri, Taufik, F. S. Buana, Preventive maintenance scheduling by modularity design applied to limestone crusher machine, Procedia Manufacturing 43 (2020) 682–687. doi:10.1016/j.promfg.2020.02.123.
- [14] A. Rastegari, Condition Based Maintenance in the Manufacturing Industry: From Strategy to Implementation, Ph.D. thesis, Mälardalen University, School of Innovation, Design and Engineering, Innovation and Product Realisation (2017).
- [15] B. Santosa, A. Umam, Data Mining and Big Data Analytics: Theory and Implementation Using Python & Apache Spark, Penebar Media Pustaka : Yogyakarta, 2018.