

Pengembangan Algoritma Predictive Maintenance Pada Coal Pfister Feeder Dengan Pendekatan Machine Learning

Essa A Wahid^{a,1}, Mehi Zulqaida H^{a,2}, Saraswati Veda P^{a,3}, Harry Patria^{a,4}

^a MMT-ITS, Jl. Cokroaminoto No.12A, DR. Soetomo, Surabaya 60264, Indonesia
¹ essawahid.206032@mhs.its.ac.id; ² zulqaida.206032@mhs.its.ac.id; ³ saraswativeda@gmail.com;
⁴ harry.patria@sbm-itb.ac.id

INFORMASI ARTIKEL

Histori Artikel

Diterima : 08 November 2021
Direvisi : 02 Februari 2022
Diterbitkan : 15 April 2022

Kata Kunci:

Predictive Maintenance
Coal Pfister Feeder
Machine Learning
Supervised Learning
Gradient Boosting

ABSTRAK

Coal Pfister Feeder adalah alat berfungsi untuk mengatur laju aliran umpan fine coal dalam proses pembakaran. Operasional yang stabil sangat bergantung pada kehandalan alat itu sendiri. Kehandalan alat dapat dicapai melalui maintenance strategy yang baik. Secara umum maintenance strategy dapat dikategorikan menjadi tiga, yaitu Corrective Maintenance (CM), Preventive Maintenance (PM), dan Predictive Maintenance (PdM). PdM adalah strategi pemeliharaan dimana aktivitas perawatan dilakukan dengan mengevaluasi dan menganalisa kondisi aktual dari alat, sehingga dapat diprediksi waktu yang optimal untuk dilakukan aktivitas perawatan sebelum kegagalan alat terjadi. Perkembangan industri 4.0 dan Digital Manufacturing semakin mendorong para pelaku industri untuk melakukan pendekatan prediktif dalam pemeliharaan alat. Aktivitas di PT XYZ mengelola data realtime operasi pabrik seperti feedrate, current load, temperature, pressure, putaran mesin, vibrasi, dan material level yang terintegrasi pada Technical Information System (TIS). Penelitian ini bertujuan membangun sebuah algoritma Predictive Maintenance yang dapat menghasilkan prediksi potensi kegagalan pada jalur proses produksi dengan menggunakan Machine Learning, dimana untuk memperoleh pemodelan yang paling sesuai untuk menyelesaikan masalah ini beberapa algoritma. Hasil evaluasi model menunjukkan bahwa Gradient Boosting memberikan hasil akurasi yang paling baik diantara model Random Forest, AdaBoost, SVM dan Neural Network.

2022 SAKTI – Sains, Aplikasi, Komputasi dan Teknologi Informasi.

Hak Cipta

I. Pendahuluan

1. Keandalan

Keandalan (*reliability*) merupakan probabilitas sistem akan melakukan fungsi yang diperlukan untuk periode tertentu ketika digunakan dalam kegiatan operasi [4]. Pengertian lain dari keandalan (*reliability*) adalah kemungkinan suatu sistem akan berjalan sesuai dengan fungsinya untuk periode waktu dan kondisi yang ditentukan [3]. Evaluasi Keandalan suatu sistem mempunyai dua metode secara umum yang biasa digunakan yaitu metode kualitatif dan metode kuantitatif [4]. Metode kuantitatif diperoleh dari data maintenance terhadap waktu kegagalan (time to failure) dan waktu perbaikan (time to repair) dari setiap komponen, sehingga dapat dikatakan sebagai metode matematis.

Berikut adalah rumus yang digunakan untuk menghitung suatu keandalan [3]:

$$R(t) = 1 - F(t) = \int_0^\infty f(t)dt$$

Dimana:

F (t) adalah *Cumulative Distribution Function* (CDF)

R (t) adalah *Reliability Function*

f (t) adalah *Probability Density Function* (PDF)

2. Maintenance

Maintenance merupakan kegiatan pengecekan dan perbaikan fungsi suatu komponen agar dapat berfungsi dengan baik dalam periode waktu tertentu [4]. Sedangkan pengertian *maintenance* [7] yaitu memastikan suatu komponen dapat berfungsi dengan baik. Secara umum *maintenance* dibagi menjadi 2 kategori yaitu *reactive maintenance* dan *proactive maintenance*.

Pada *reactive maintenance* terdapat 2 (dua) jenis, yaitu *corrective maintenance* dan *breakdown maintenance*, sedangkan jenis *proactive maintenance* yaitu *preventive maintenance* dan *predictive maintenance*.

3. Predictive maintenance

Teknik *predictive maintenance* (PdM) melakukan estimasi melalui pengukuran, ketika suatu bagian mesin hampir mengalami kerusakan dan harus diperbaiki atau diganti, sehingga mengurangi biaya perawatan yang tidak terjadwal [4].

Predictive maintenance meningkatkan keandalan (reliability) dengan mendeteksi kerusakan lebih awal daripada yang dapat dideteksi secara manual, yang memberikan waktu yang lebih kepada petugas *maintenance* untuk melakukan perawatan [6].

4. Machine learning pada predictive maintenance

Predictive maintenance memang tidak memerlukan apapun selain perhitungan matematis informal pada saat kondisi mesin berada pada kondisi yang perlu diperbaiki atau bahkan diganti sehingga pemeliharaan dapat dilakukan dengan tepat, kapan dan dengan cara yang paling efektif, namun *machine learning* dapat menghilangkan sebagian besar dugaan dan membantu manajer fasilitas fokus pada tugas lain [5].

Machine learning memungkinkan untuk:

- a. Membuat model prediksi untuk memaksimalkan masa manfaat, operasional, efisiensi maupun waktu aktif dari asset
- b. Memanfaatkan data masa lalu maupun berkelanjutan
- c. Mengoptimalkan operasi pemeliharaan berkala
- d. Menghindari atau meminimalkan waktu henti, yang memungkinkan dapat menghindari komplain pelanggan, menghemat biaya dan menyelamatkan hidup

5. Gradient Boosting - XGBoosting

XGBoosting (*Extreme Gradient Boosting*) merupakan versi lanjutan dari *gradient boosting* dengan struktur yang sama implementasi dari *gradient boosting* yang diperkenalkan oleh Tianqi Chen. *XGBoosting* mendominasi kumpulan data yang terstruktur pada permasalahan pemodelan prediksi klasifikasi dan regresi [1].

XGBoosting menunjukkan konsistensi, kekuatan dan hasil yang memuaskan dari *gradient boosting* yang diperkenalkan oleh Tianqi Chen untuk meningkatkan kapabilitasnya, serta memasukkan unsur regularisasi bawaan dan meningkatkan kecepatan [11].

6. Random Forest (RF) Algorithm

Random Forest adalah algoritma supervised classification yang menciptakan hutan (*forest*) dengan sejumlah pohon (*tree*). Semakin banyak jumlah *tree* di *forest*, maka akan semakin kuat tampilan *forest*-nya. Demikian juga pengklasifikasian pada *random forest*, semakin tinggi jumlah *tree* maka akan memberikan hasil akurasi yang tinggi [8].

Konsep *Decision Tree* lebih mengarah pada sistem berbasis aturan. *Training dataset* dengan target dan fitur, algoritma *decision tree* akan muncul dengan beberapa aturan set (*set of rules*). Aturan set dapat digunakan untuk menampilkan prediksi pada dataset yang diuji [8].

II. Material dan Metode

A. Pengumpulan data

Data yang digunakan merupakan parameter operasi pada *coal pfister feeder*. Data tersebut diperoleh dari pembacaan sensor yang terpasang di jalur produksi, dimana pembacaan sensor dihitung dalam satuan jam. Sensor yang terpasang membaca beberapa parameter kunci dalam operasi, diantaranya temperatur, kecepatan putaran, tekanan udara, laju massa, dan kuat arus listrik. Data yang digunakan dalam penelitian ini terdiri dari 17 kolom dan 5093 baris.

B. Pemrosesan data awal

Data yang diunduh dari sistem informasi pabrik merupakan data mentah sehingga perlu melewati beberapa proses sampai data siap digunakan. Berikut ini pemrosesan data awal yang terbagi menjadi beberapa bagian :

- Pembersihan data

Sensor-sensor yang terpasang di alat beberapa kali mengalami error dimana pembacaan data jauh dari rata-rata nilai. Data tersebut tetap terekam di dalam sistem informasi pabrik, sehingga data mentah yang diunduh perlu dibersihkan data outlier ataupun data error lainnya.

- Pengisian nilai yang kosong

Sama halnya dengan data outlier dan data error, beberapa kali sensor mengalami gangguan sehingga tidak dapat membaca dan merekam data. Oleh karena itu nilai dari data yang kosong perlu diisi dengan rata-rata dari total semua nilai dalam fitur tersebut. Pada penelitian ini metode yang digunakan adalah Model Based Imputation, dimana nilai yang hilang diisi dengan asumsi nilai menggunakan distribusi data yang ada. Nilai yang kosong dalam dataset ini berjumlah 3.7 %.

- Analisis korelasi dan pemilihan fitur

Analisa korelasi dilakukan dengan menguji semua data dalam sebuah matriks korelasi. Kemudian setelah diketahui fitur atau parameter yang memiliki korelasi yang kuat, maka fitur tersebut diteruskan ke proses berikutnya di pengembangan pemodelan.

C. Pengembangan model algoritma.

Data mentah yang telah mengalami pemrosesan awal siap untuk diolah pada untuk pengembangan model algoritma. Data dibagi menjadi dua bagian dimana 70% data set digunakan sebagai data pembelajaran dan 30% sisanya menjadi data pengujian. Pemodelan algoritma yang digunakan dalam pengembangan model ini adalah *random forest*, *gradient boosting*, dan *XGBoosting*.

D. Interpretasi hasil dan pemilihan pemodelan algoritma yang terbaik

Hasil dari pemodelan algoritma tersebut kemudian dievaluasi dan saling dibandingkan hasilnya. Parameter yang diperhatikan adalah *R-squared* (R2), *Mean Absolute Error* (MAE), *Mean Square Error* (MSE), dan *Root Mean Squared Error* (RMSE). *R-squared* (R2) mengindikasikan kecocokan model terhadap keseluruhan data, dimana semakin besar R2 maka model tersebut makin baik. *Mean Absolute Error* (MAE) merupakan nilai absolut rata-rata perbedaan antara prediksi dengan aktual. Semakin rendah nilai *Mean Absolute Error* (MAE) maka prediksi dari algoritma tersebut terhadap potensi kegagalan makin baik. *Root Mean Squared Error* (RMSE) adalah parameter lain yang biasa digunakan untuk mengukur standard deviasi dari prediction error.

III. Hasil dan Pembahasan

Dari evaluasi model didapatkan hasil sebagaimana tertera pada Tabel 1. Hasil terbaik diperoleh oleh algoritma yang menggunakan pemodelan *Gradient Boosting* dengan nilai *R-squared* (R2) 0.942. Sementara pemodelan *Random Forest* dan *AdaBoost* memiliki nilai *R-squared* (R2) yang berdekatan yaitu 0.886 dan 0.880. Nilai *R-squared* (R2) terendah diperoleh oleh pemodelan *Neural Network* dengan angka 0.669.

Tabel 1. Hasil Test & Score Pemodelan

Model	MSE	RMSE	MAE	R2
Random Forest	0.376	0.613	0.086	0.886
Neural Network	1.095	1.046	0.550	0.669
Gradient Boosting	0.190	0.436	0.078	0.942
AdaBoost	0.395	0.629	0.083	0.880

Pfister Coal Feeder merupakan salah satu peralatan kritikal dalam proses produksi dimana kegagalan pada alat dapat menyebabkan jalur produksi terhenti. Kegagalan yang berulang maupun yang menyebabkan durasi stop panjang dapat dihindari melalui strategi pemeliharaan yang tepat. Strategi pemeliharaan yang tepat akan meningkatkan kehandalan dari alat tersebut. Parameter kunci pada operasi *pfister coal feeder* terekam oleh berbagai sensor yang terintegrasi pada *Technical Information System (TIS)*.

Penelitian ini melakukan pendekatan *machine learning* dalam memanfaatkan data yang tersimpan pada *Technical Information System (TIS)* untuk aktifitas *predictive maintenance* di *pfister coal feeder*. Parameter *current load* dijadikan sebagai variabel target, dengan *feedrate*, *temperature*, *pressure*, putaran mesin, vibrasi, dan material level, sebagai variabel prediktor.

Beberapa algoritma *machine learning* yang dihasilkan akan diuji dengan, menunjukkan bahwa *gradient boosting* menunjukkan hasil yang terbaik. Hal ini sejalan dengan penelitian yang menyebutkan bahwa teknik pembelajaran *ensemble* diketahui memiliki performa yang baik dalam memprediksi dibanding individual algoritma *machine learning* [9] [10].

Keterbatasan dalam penelitian ini bahwa dataset yang dikumpulkan hanya berasal dari sistem pengumpan bahan bakar di area pabrik 2. Meskipun dengan jenis alat yang sama, namun parameter proses yang berbeda sehingga model ini hanya dapat diimplementasikan untuk sistem tersebut. Pengembangan lebih lanjut perlu dilakukan jika akan diimplementasikan di sistem pengumpan bahan bakar di area pabrik 1.

Di penelitian berikutnya perlu dipertimbangkan agar sistem pemodelan dirangkai dengan sub-proses produksi yang juga berkaitan dengan sistem pengumpan bahan bakar. Hal ini dikarenakan dalam sistem operasi pabrik, kegagalan yang menyebabkan pabrik mati tidak hanya dari satu sub proses, namun beberapa sub proses yang perlu dipelajari lebih dalam keterkaitannya satu sama lain.

IV. Kesimpulan

Penelitian algoritma *predictive maintenance* dibangun menggunakan data parameter operasi yang terintegrasi pada sistem informasi *Technical Information System (TIS)*. Beberapa model algoritma *machine learning* kemudian diuji efektivitasnya. Dari hasil pemodelan ditemukan beberapa faktor yang paling mempengaruhi operasi dan kegagalan dari alat tersebut. Hal ini akan mempermudah tim operasi dalam memelihara dan mengoperasikan alat berdasarkan perilaku dari alat. Hasil evaluasi menunjukkan bahwa model *ensemble* menunjukkan hasil prediksi yang paling baik.

Ucapan Terima Kasih

Dalam penyusunan jurnal artikel ini tidak terlepas dari dukungan berbagai pihak. Penulis dengan ini mengucapkan terima kasih yang sebesar-besarnya kepada dosen pembimbing Bapak Harry Patria dan rekan-rekan kelas *Predictive Analytical and Machine Learning*.

Daftar Pustaka.

- [1] Brownlee, J. (2018). *XGBoost With Python - Gradient Boosted Trees With XGBoost and scikit-learn*.
- [2] Chistou, I. T., Kefalakis, N., Zalonis, A., Soldatos, J., & Brochler, R. (2020). End-to-End Industrial IoT Platform for Actionable Predictive Maintenance. *IFAC PaperOnline*, 173-178.
- [3] Dhillon, B. (2005). *Reliability, Quality, and Safety for Engineers*. New York: CRC PRESS.
- [4] Ebeling, C. (1997). *An Introduction To Reliability and Maintainability Engineering*. New York: McGraw-Hill.
- [5] Gonfalonieri, A. (2019, November 7). Retrieved from towards data science: <https://towardsdatascience.com/how-to-implement-machine-learning-for-predictive-maintenance-4633cdbc4860>
- [6] Levitt, J. (2011). *Complete Guide to Preventive and Predictive Maintenance Second Edition*. New York: Industrial Press Inc.
- [7] Moubay, J. (1999). *Reliability-centred Maintenance II*. North Carolina: The Aladon Network.
- [8] Polamuri, S. (2017, May 22). Retrieved from Dataaspirant: <https://dataaspirant.com/random-forest-algorithm-machine-learning/>
- [9] Polikar, R. (2006). Ensemble based systems in decision making. *IEEE Circuits and Systems Magazine*, 21-45.
- [10] Rokach, L. (2010). Ensemble-based classifiers. *Artificial Intelligence Review* 33, 1-39.
- [11] Wade, C. (2020). *Hands-On Gradient Boosting with XGBoost and scikit-learn*. Birmingham: Packt Publishing.
- [12] Weiting, Z., Dong, Y., & Hongcao, W. (2019). *Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey*. Computer Science.