

Pengembangan Model Machine Learning Parameter Mesin Terhadap Temperatur Pada Mesin Sir Degasser Di Pt Xyz Menggunakan *Extreme Gradient Boosting*

1st Alvito Ahmad Cannavaro Idham

Fakultas Rekayasa Industri

Universitas Telkom

Bandung, Indonesia

alvitoac@student.telkomuniversity.ac.id

2nd Murman Dwi Prasetyo

Fakultas Rekayasa Industri

Universitas Telkom

Bandung, Indonesia

murmandwi@telkomuniversity.ac.id

3rd Teddy Sjafrizal

Fakultas Rekayasa Industri

Universitas Telkom

Bandung, Indonesia

teddysjafrizal@telkomuniversity.ac.id


Abstrak — Proses degassing penting dalam pembuatan billet aluminium untuk menghilangkan pori yang dapat mengurangi properti mekanik. Mesin degasser penting dalam proses ini untuk menyuntikan gas argon dan mengaduk aluminium cair untuk menghilangkan gelembung gas terperangkap. Kontrol suhu penting dalam proses degassing yang lancar sehingga sebuah model yang memberikan perkiraan nilai suhu dapat membantu penyesuaian langsung pada parameter mesin untuk menjaga suhu. Pemodelan aspek-aspek proses menggunakan mesin atau juga dikenal sebagai machine learning semakin marak digunakan dalam industri. Studi ini akan menggunakan konsep dalam machine learning yang disebut sebagai extreme gradient boosting, dan memberikan hasil terbaik ketika semua variabel, yaitu torsi rotor, penggunaan ejektor, dan tekanan udara, menjadi variabel input. Model ini dapat membantu seorang operator dalam melakukan penyesuaian langsung terhadap tekanan udara, penggunaan ejektor, dan torsi rotor untuk menjaga suhu tetap optimal. Model yang dihasilkan memberikan kesalahan rata-rata atau MAE sebesar 13.06°C dan rata-rata kesalahan relatif atau MAPE sebesar 2.523%.

Kata kunci— suhu, machine learning, degassing, rotor, tekanan

I. PENDAHULUAN

Aluminium adalah logam yang banyak digunakan di berbagai industri karena ringan dan ketahanan korosi yang baik. Properti ini membuatnya ideal untuk aplikasi di sektor otomotif, kedirgantaraan, dan konstruksi. Untuk menjaga kualitas-kualitas tersebut harus dihindari gas terperangkap dalam aluminium. Perubahan mikrostruktur yang disebabkan oleh gas yang terperangkap menunjukkan bahwa porositas gas dapat mengganggu keseragaman struktur mikro, yang menghasilkan kinerja yang tidak dapat diprediksi, terutama dalam situasi beban dinamis [1] Sementara itu, terdapat tantangan dalam mendeteksi dan mengurangi gas terperangkap selama proses pembuatan yang menekankan pentingnya teknik produksi yang baik seperti pengecoran vakum dan degassing untuk mengurangi porositas dan

meningkatkan sifat mekanik paduan aluminium [2]. Dengan demikian, pengendalian gas yang terperangkap selama proses peleburan dan pengecoran aluminium menjadi sangat penting untuk memastikan integritas dan kinerja produk akhir.



GAMBAR 1
(A)

Untuk mengatasi masalah gas terjebak, berbagai teknik degassing digunakan. Salah satu metode tersebut adalah penggunaan degasser impeller berputar, yang membantu menghilangkan gas terlarut dari aluminium cair dengan menciptakan ruang hampa dan mengaduk lelehan. Diagram skematis dari degassing menggunakan rotor konvensional dapat dilihat dalam gambar 1 (A). Degasser impeller berputar meningkatkan kontak antara logam cair dan agen degassing, yang memfasilitasi penghilangan gas secara lebih efisien dan menghasilkan paduan aluminium berkualitas lebih tinggi. Degassing yang tepat dari paduan aluminium dapat meningkatkan kekuatan tarik dan ketahanan lelah secara signifikan, serta memastikan struktur mikro yang lebih seragam dan bebas cacat. Maka, degassing adalah langkah penting dalam produksi paduan aluminium berkualitas tinggi. Teknik seperti degasser impeller berputar memainkan peran penting dalam memastikan bahwa produk akhir bebas dari cacat yang disebabkan oleh gas, sehingga meningkatkan

kinerja dan keandalannya dalam berbagai aplikasi industri [3].

Pemodelan suhu dalam degassing aluminium sangat penting karena dampaknya yang signifikan pada sifat material dan kualitas produk akhir. Dalam konteks peleburan aluminium, sebuah jaringan saraf buatan dapat mengoptimalkan pengukuran suhu, mengurangi biaya operasional dan penundaan, soft sensor hasil dari jaringan saraf buatan tersebut sangat bermanfaat di lingkungan korosif seperti smelter aluminium [4]. Pemodelan regresi menggunakan extreme gradient boosting telah menunjukkan kinerja prediktif yang unggul di berbagai domain, sebagaimana dibuktikan oleh beberapa penelitian. Di pasar elektronik konsumen, terutama untuk memprediksi harga laptop, XGBoost telah menunjukkan akurasi tertinggi dan paling cocok di antara model regresi linier dan random forest, dengan RMSE 294,11 dan nilai R² 0,85, menunjukkan kekokohnya dalam menangani kumpulan data kompleks dengan beberapa fitur seperti merek, jenis, ukuran layar, RAM, GPU, sistem operasi, dan berat [5]. Demikian pula, di bidang medis, extreme gradient boosting mengungguli regresi logistik tradisional dalam memprediksi sepsis pada pasien dengan luka bakar yang sangat parah, mencapai AUC (Area under Curve) yang lebih tinggi 0,91 dibandingkan dengan 0,88 untuk model regresi logistik. Fitur penting yang diidentifikasi termasuk fibrinogen, NLR, BI, dan usia [6]. Studi-studi ini secara kolektif menyoroti keserbagunaan dan kemanjuran extreme gradient boosting dalam pemodelan regresi di berbagai aplikasi, menjadikannya alat yang berharga untuk pemodelan suhu dalam degassing.

II. KAJIAN TEORI

A. Degassing

Proses degassing melibatkan penyuntikan gas argon ke dalam cairan logam aluminium guna menghilangkan kandungan hidrogen. Energi yang dihasilkan dari poros yang berputar menyebabkan timbulnya banyak gelembung kecil secara masif, sehingga memberikan proses ini rasio permukaan yang sangat besar dibandingkan volumenya. Area permukaan yang luas ini mendorong hidrogen untuk menyebar dengan cepat dan efisien ke dalam gelembung gas, sehingga menciptakan keseimbangan aktivitas hidrogen antara fase cair dan gas. Salah satu teknik perlakuan logam cair yang sering digunakan dalam industri pengecoran adalah degassing rotasi. Gelembung gas kecil yang terdistribusi merata muncul ketika gas argon didorong masuk ke dalam cairan logam dengan bantuan impeller yang berputar. Selain membawa keluar kontaminan dari logam cair, gelembung tersebut juga mampu menangkap hidrogen yang larut di dalamnya. Degassing berotasi biasanya dilakukan bersamaan dengan penambahan flux, yang secara signifikan dapat meningkatkan efisiensi penghilangan inklusi dalam proses perlakuan tersebut. [3]

B. Extreme Gradient Boosting

Extreme Gradient Boosting, biasa disebut sebagai XGBoost, adalah algoritma pembelajaran mesin canggih yang merupakan bagian dari keluarga pembelajaran ensemble. Ini dirancang untuk meningkatkan kinerja model prediktif dengan menggabungkan prediksi beberapa pelajar yang lemah, biasanya pohon keputusan, untuk membentuk

model prediktif yang kuat. XGBoost terkenal dengan kecepatan, skalabilitas, dan efisiensinya, menjadikannya pilihan populer untuk berbagai aplikasi di berbagai domain yang berbeda. Algoritma beroperasi dengan menambahkan model secara berulang untuk memperbaiki kesalahan yang dibuat oleh model sebelumnya, mengoptimalkan kinerja model melalui teknik peningkatan gradien. Proses ini melibatkan meminimalkan fungsi kerugian, yang mengukur perbedaan antara hasil yang diprediksi dan aktual, dan menerapkan regularisasi untuk mencegah kelebihan pemasangan, sehingga meningkatkan kemampuan generalisasi model [7], [8], [9].

C. Evaluation Metric

Hasil model akan dievaluasi menggunakan mean absolute error (MAE) dan mean absolute percentage error (MAPE). Mean absolute error (MAE) adalah ukuran rata-rata dari kesalahan absolut antara nilai yang diprediksi oleh model dan nilai aktual dari data. MAE memberikan gambaran seberapa besar kesalahan rata-rata dari prediksi model tanpa memperhatikan arah kesalahan (positif atau negatif). Ini dihitung sebagai rata-rata dari jumlah nilai mutlak kesalahan, sebagaimana dalam rumus berikut,

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

dengan n adalah jumlah observasi y_i adalah nilai aktual dan $\hat{y}_i$ adalah hasil prediksi. Mean absolute percentage error (MAPE) adalah ukuran rata-rata dari kesalahan absolut yang dinyatakan dalam persentase dari nilai aktual. MAPE memberikan gambaran seberapa besar kesalahan rata-rata dari prediksi model dalam bentuk persentase dari nilai aktual. Ini berguna untuk memahami kesalahan dalam skala relatif. Seperti dalam rumus berikut,


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%$$

dengan n adalah jumlah observasi, y_i adalah nilai aktual dan $\hat{y}_i$ adalah hasil prediksi.

III. METODE PENELITIAN

A. Sistematika Penelitian

Sistematika penelitian terdiri dari beberapa langkah yang dilakukan selama pengerjaan penelitian ini yang bersifat terstruktur dan sistematis. Dimulai dari tahap awal identifikasi masalah hingga tahap hasil dan saran. Sistematika penulisan yang terdiri dari beberapa langkah dilakukan sebagai berikut:



Gambar III. 1
Sistematika Penelitian

1. Tahap Pengumpulan Data



GAMBAR III. 2
Sistematika Penelitian

Data penelitian diambil dari mesin SIR-751. Dalam proses produksi aluminium billet, mesin SIR-751 berperan sebagai Gas Exhaust System, yaitu bagian dari proses yang mengeluarkan gas pengotor dari aluminium cair. Dapat dilihat pada diagram hubungan dalam gambar III.2, mesin SIR-751 memiliki 4 sensor yang bertanggung jawab untuk mengukur suhu, tekanan udara, penggunaan ejektor, dan torsi dari rotor pengaduk. Gambar III.3 menggambarkan

hubungan sensor pada controller, keempat sensor tersebut ini melapor kepada PLC Allen Bradley Compactlogix L24ER yang selanjutnya akan mengirimkan data secara real-time kepada InfluxDB sebagai database penyimpanan data. Pengiriman data dilakukan melalui API NodeRed dan RabbitMQ Broker.

Data penelitian diakses menggunakan interface InfluxDB untuk mengekspor data periode 21 Februari 2024 hingga 5 Juni 2024 dalam format CSV. Data ini kemudian di format ulang menggunakan Microsoft Excel dan dijadikan kolom yang lebih mudah dibaca oleh Python. Pembuatan susunan yang diformat dengan benar ini mengakhiri tahap pengumpulan data.

2. Tahap Pengolahan Data

Setelah data melewati tahap pre-processing, akan dilakukan pemodelan suhu chamber pada SIR Degasser dengan menggunakan variabel-variabel yang berperan penting dalam proses tersebut, yaitu torsi rotor, penggunaan ejektor, dan tekanan udara. Variabel torsi rotor akan dihitung sebagai rata-rata dari dua torsi yang ada, sementara penggunaan ejektor merupakan nilai vakum dalam chamber, dengan semakin rendah nilainya maka semakin baik vakum dan tekanan udara, sebagai ukuran tekanan dalam chamber. Dengan memanfaatkan ketiga variabel ini, model suhu yang dihasilkan diharapkan dapat memberikan prediksi yang akurat terhadap perubahan suhu yang terjadi dalam chamber SIR Degasser.

3. Tahap Analisis

Hasil dari model ini akan dianalisis dengan menggunakan tiga metrik utama: Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE). MAE akan memberikan informasi mengenai rata-rata selisih absolut antara nilai yang diprediksi oleh model dengan nilai aktual, sedangkan MAPE mengukur kesalahan prediksi dalam bentuk persentase, memberikan gambaran yang lebih intuitif tentang akurasi model. Dengan menggunakan metrik-metrik ini, studi ini akan memberikan gambaran yang komprehensif tentang performa model suhu yang dibangun.

IV. HASIL DAN PEMBAHASAN

Model XGBoost dibuat menggunakan kombinasi variabel penggunaan ejektor, torsi rotor, dan tekanan udara yang ditangkap oleh sensor pada mesin SIR-751. Kombinasi dari ketiga variabel ini memberikan model prediksi yang paling akurat, karena semua variabel yang dapat diukur dalam mesin SIR Degasser dipertimbangkan secara bersamaan. Dengan menggunakan ketiga variabel ini, model dibuat untuk menangkap interaksi kompleks antara penggunaan ejektor, torsi rotor, dan tekanan udara untuk memprediksi suhu dengan lebih baik. Model yang dibuat adalah sebuah *random decision forest* yang dioptimasi menggunakan *extreme gradient boosting*, yaitu memberikan sebuah nilai regresi berdasarkan input dari ketiga variabel yang terdapat dalam mesin SIR-751.

TABEL 1
(5 INPUT DAN OUTPUT PERTAMA HASIL MODEL XGBOOST)

<i>Ejector Use</i>	<i>Average Rotor Torque</i>	<i>Air Pressure</i>	<i>Suhu Actual</i>	<i>Suhu hasil Model</i>
46.940	132.000	5.904	497.3	516.842
-0.290	0.000	5.410	529.7	531.436
66.280	175.500	5.112	502.6	478.844
45.050	136.500	5.091	557.0	529.737
46.780	125.000	5.851	536.4	529.747

Dalam proses, model dapat digunakan untuk memperkirakan suhu ketika menggunakan pengaturan baru. Model yang dapat digunakan adalah yang menggunakan semua variabel dengan MAE sebesar 13.06°C. Keakuratan model dapat digambarkan dengan nilai MAPE yang menunjukkan bahwa hasil dari model berada dalam jarak 2.523% dari nilai aktual.

Untuk studi dalam bidang memodelkan parameter suhu menggunakan data sensor pada mesin ke depannya, hasil penelitian ini mengajukan saran berikut:

1. Tingkat kesalahan yang lebih kecil dapat dicapai dengan menggunakan dataset yang lebih beragam, yaitu dengan menambahkan variabel input. Menggunakan masing-masing variabel, kombinasi 2 variabel, dan kombinasi semua 3 variabel menunjukkan peningkatan pada nilai r-squared dan penurunan tingkat kesalahan mutlak rata-rata seiring bertambahnya variabel.
2. Model XGBoost juga menunjukkan hasil terbaik dibandingkan model regresi linear, decision tree, SVR (Support Vector Regression), MLP (Multi-layer Perceptron), dan random forest sehingga menunjukkan XGBoost dapat dijadikan pilihan dalam pemodelan suhu pada studi-studi selanjutnya.
3. Model suhu dapat diaplikasikan sebagai alat hitung dalam sistem monitoring pada mesin SIR Degasser dan untuk studi peningkatan akurasi thermocouple.

V. KESIMPULAN

Model XGBoost memodelkan arus torsi rotor, penggunaan ejektor, dan tekanan udara dari sensor pada mesin SIR Degasser pada suhu chamber dalam proses degassing. Model memberikan kesalahan rata-rata atau MAE sebesar 13.06°C dan persentase kesalahan sebesar 2.523%. Hasil model XGBoost juga memberikan hasil terbaik dibandingkan model-model yang digunakan lainnya. Tingkat presisi ini relatif cukup baik dan menunjukkan potensi dalam aplikasi industrial. Dapat disimpulkan bahwa model XGBoost dapat digunakan dalam proses untuk mendapatkan perkiraan suhu yang akurat pada pengaturan baru.

REFERENSI

[1] P. Zhang dkk., “Investigation of trap states in Al 2 O 3 InAlN/GaN metal–oxide–semiconductor high-electron-mobility transistors,” Chinese Physics B, vol. 24, no. 12, hlm. 127306, Des 2015, doi: 10.1088/1674-1056/24/12/127306.

[2] H. Kamoutsi, G. N. Haidemenopoulos, V. Bontozoglou, P. V. Petroyiannis, dan Sp. G. Pantelakis, “Hydrogen Trapping: Deformation and Heat Treatment Effects in 2024 Alloy,” dalam Fracture of Nano and Engineering Materials and Structures, Dordrecht: Springer Netherlands, 2006, hlm. 1293–1294. doi: 10.1007/1-4020-4972-2_642.

[3] C. Rathinasuriyan, K. Karthik, dan K. Sridhar, “Investigation of degassing on aluminum alloy by rotatory impeller degasser,” Mater Today Proc, Mar 2023, doi: 10.1016/J.MATPR.2023.03.263.

[4] F. M. Soares dan R. C. L. Oliveira, “Modelling of temperature in the aluminium smelting process using Neural Networks,” dalam The 2010 International Joint Conference on Neural Networks (IJCNN), IEEE, Jul 2010, hlm. 1–7. doi: 10.1109/IJCNN.2010.5596645.

[5] P. Tian, “Research On Laptop Price Predictive Model Based on Linear Regression, Random Forest and Xgboost,” Highlights in Science, Engineering and Technology, vol. 85, hlm. 265–271, Mar 2024, doi: 10.54097/9nx5ad16.

[6] P. Liu, X.-J. Li, T. Zhang, dan Y.-H. Huang, “Comparison between XGboost model and logistic regression model for predicting sepsis after extremely severe burns,” Journal of International Medical Research, vol. 52, no. 5, Mei 2024, doi: 10.1177/03000605241247696.

[7] Muhamad Fikri, “Klasifikasi Status Stunting Pada Anak Bawah Lima Tahun Menggunakan Extreme Gradient Boosting,” Mercurius : Jurnal Riset Sistem Informasi dan Teknik Informatika, vol. 2, no. 4, hlm. 173–184, Jun 2024, doi: 10.61132/mercurius.v2i4.159.

[8] Q. Zhao, X. Liu, dan J. Fang, “Extreme Gradient Boosting Model for Day-Ahead STLF in National Level Power System: Estonia Case Study,” Energies (Basel), vol. 16, no. 24, hlm. 7962, Des 2023, doi: 10.3390/en16247962.

[9] Y. Pristyanto, Z. Mukarabiman, dan A. F. Nugraha, “Extreme Gradient Boosting Algorithm to Improve Machine Learning Model Performance on Multiclass Imbalanced Dataset,” JOIV : International Journal on Informatics Visualization, vol. 7, no. 3, hlm. 710–715, Sep 2023, doi: 10.30630/joiv.7.3.1102.