



Analisa Penjadwalan Produksi Alat Elektronik dengan Algoritma Random Forest di PT Elektronik Indonesia Cemerlang

Anotaris Bulele¹, Adam Muiz^{2*}

^{1,2} Jurusan Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang, Kota Tangerang Selatan, Banten

Email: ¹anotaris.buulolo27@gmail.com, ^{2*}dosen02369@unpam.ac.id

Abstrak—Dalam dunia industri manufaktur, efisiensi produksi merupakan faktor utama yang memengaruhi daya saing dan profitabilitas perusahaan. Salah satu tantangan penting yang dihadapi adalah memperkirakan waktu produksi secara akurat untuk setiap jenis produk. Estimasi yang tepat dapat membantu perusahaan dalam perencanaan sumber daya, penjadwalan produksi, serta pengendalian biaya. Namun, proses estimasi yang masih dilakukan secara manual sering kali [1] menghasilkan ketidakakuratan akibat kompleksitas variabel seperti permintaan pasar, stok bahan baku, dan jumlah tenaga kerja. Penelitian ini bertujuan untuk membangun model prediksi waktu produksi menggunakan algoritma Random Forest yang diimplementasikan pada aplikasi berbasis web Streamlit. Model dilatih dengan data produksi alat elektronik yang mencakup variabel-variabel seperti jenis produk, jumlah permintaan, stok bahan baku, jumlah mesin aktif, dan tenaga kerja. Proses penelitian meliputi tahapan Exploratory Data Analysis (EDA), pembagian data latih dan data uji, serta tuning hyperparameter untuk memperoleh performa terbaik hasil pengujian menunjukkan bahwa model Random Forest memiliki nilai akurasi tinggi dengan R^2 sebesar 0.884 dan Mean Squared Error (MSE) sebesar 32.64, yang menandakan kemampuan model dalam memprediksi waktu produksi dengan baik. Analisis residual juga menunjukkan distribusi yang mendekati normal tanpa adanya bias sistematis.

Kata Kunci: Machine Learning, Random Forest, Prediksi Waktu Produksi, Streamlit, Industri Manufaktur

Abstract—In the manufacturing industry, production efficiency is a crucial factor influencing a company's competitiveness and profitability. One of the main challenges is accurately estimating production time for each type of product. Inaccurate estimations can negatively impact resource planning, production scheduling, and operational cost control. This study aims to develop a production time prediction model for electronic products using the Random Forest algorithm, integrated into a web-based application developed with the Streamlit framework. The dataset consists of historical production data including product type, demand quantity, raw material stock, number of active machines, and workforce availability. The research stages include data preprocessing, Exploratory Data Analysis (EDA), train-test data splitting, and hyperparameter tuning to obtain optimal model performance. The experimental results indicate that the Random Forest model achieved strong performance with an R^2 value of 0.884 and a Mean Squared Error (MSE) of 32.64. The most influential variable affecting production time is demand quantity, followed by raw material stock and workforce. The developed application provides real-time production time estimation, supporting data-driven decision-making and improving production efficiency in manufacturing operations.

Keywords: Machine Learning, Random Forest, Production Time Prediction, Streamlit, Manufacturing Industry.

1. PENDAHULUAN

Dalam dunia industri manufaktur, efisiensi produksi merupakan faktor penting yang memengaruhi daya saing dan profitabilitas perusahaan. Salah satu tantangan utama yang dihadapi oleh pelaku industri adalah memperkirakan waktu produksi secara akurat untuk setiap jenis produk. Perkiraan yang tepat tidak hanya membantu dalam perencanaan sumber daya, tetapi juga berkontribusi terhadap penjadwalan produksi, pengendalian biaya, dan kepuasan pelanggan.

2. METODE

Produksi merupakan proses transformasi bahan baku menjadi barang jadi yang memiliki nilai tambah melalui pemanfaatan sumber daya seperti mesin, tenaga kerja, dan teknologi. Dalam industri manufaktur, efisiensi waktu produksi menjadi indikator penting yang memengaruhi produktivitas, biaya operasional, serta daya saing perusahaan. Lama waktu produksi dipengaruhi



JRIIN : Jurnal Riset Informatika dan Inovasi
Volume 3, No. 12 Tahun 2026
ISSN 3025-0919 (media online)
Hal 3146-3150

oleh berbagai faktor, antara lain jenis produk, jumlah permintaan, ketersediaan bahan baku, jumlah mesin yang beroperasi, dan jumlah tenaga kerja. Ketidaktepatan dalam memperkirakan waktu produksi dapat menyebabkan keterlambatan pengiriman, pemborosan sumber daya, dan penurunan kepuasan pelanggan.

2.1 Metode Penelitian

Metodologi penelitian merupakan langkah-langkah sistematis yang digunakan dalam pelaksanaan penelitian ini untuk mencapai tujuan yang telah ditetapkan. Metode yang digunakan dalam penelitian ini adalah metode kuantitatif dengan pendekatan eksperimen menggunakan data historis produksi. Adapun langkah-langkah dalam penelitian ini

2.1.1 Produksi dalam Industri Manufaktur

Produksi adalah proses mengubah bahan mentah menjadi barang jadi yang memiliki nilai tambah, melalui penggunaan tenaga kerja, mesin, dan bahan baku. Dalam konteks industri manufaktur, waktu produksi merupakan salah satu elemen penting yang menentukan efisiensi dan produktivitas perusahaan. Lama produksi dipengaruhi oleh berbagai faktor seperti jenis produk, jumlah permintaan, ketersediaan bahan baku, jumlah mesin yang beroperasi, dan jumlah tenaga kerja

2.2 Regresi Linear

Regresi linear merupakan salah satu metode statistik yang dipergunakan untuk melakukan peramalan atau prediksi [5] yang bertentangan karakteristik kualitas maupun kuantitas. Linear regresi ini terdiri dari satu buah variable bebas (x) dan satu buah variable terikat (y). Dengan ini melakukan prediksi yang menggunakan Metode linear regresi dapat memberikan informasi lebih akurat. Dengan metode ini didasari hasil pengujian dan keakurasaan terhadap tipe yang menampilkan nilai MSE, RMSE, dan juga MAPE yang memenuhi standart. Regresi Linear variable bebas (x) dan variable terikat (y)

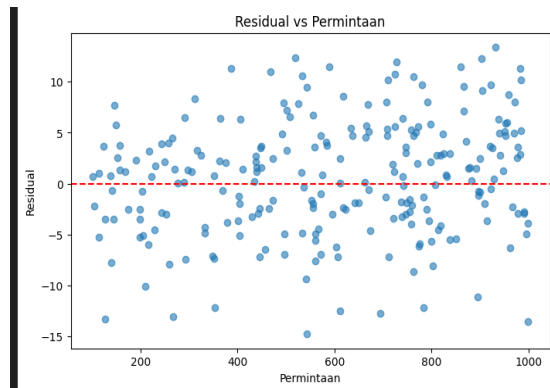
2.3 Overfitting dan Underfitting

Dalam pengembangan model machine learning, terdapat dua masalah utama yang sering muncul, yaitu overfitting dan underfitting.

- Overfitting terjadi ketika model terlalu “hafal” pada data pelatihan (training data) hingga mampu memprediksi dengan sangat baik pada data tersebut, tetapi gagal ketika digunakan pada data baru (testing data). Hal ini biasanya terjadi karena model terlalu kompleks, terlalu banyak parameter, atau terlalu lama dilatih. Solusinya adalah dengan menggunakan *regularisasi*, menambah data latih, melakukan [6] *early stopping*, atau menyederhanakan arsitektur model.
- Underfitting terjadi ketika model terlalu sederhana sehingga tidak mampu mengenali [7] pola dalam data. Biasanya disebabkan oleh pemilihan algoritma yang terlalu lemah atau jumlah fitur yang terlalu sedikit. Untuk mengatasinya, dapat [8] digunakan model yang lebih kompleks, menambahkan fitur yang relevan, atau memperbaiki preprocessing data.
- Jenis-jenis machine learning—supervised, [9]unsupervised, dan reinforcement learning—merupakan fondasi penting dalam memahami bagaimana komputer dapat belajar dari data maupun interaksi dengan lingkungan. [10]Ketiganya memiliki karakteristik, algoritma, serta kelebihan dan keterbatasan masing-masing. Dengan memahami perbedaan tersebut, praktisi dapat memilih pendekatan terbaik sesuai permasalahan.

Di era revolusi industri 4.0, machine learning terus berkembang tidak hanya dari sisi teknologi, tetapi juga penerapannya di kehidupan nyata.

2.4 Residual dan Permintaan



Gambar 1. Residual vs Permintaan

Berdasarkan gambar di atas bahwa, Titik-titik residual tersebar secara acak di sekitar garis horizontal merah ($y = 0$). Tidak terdapat pola yang jelas antara kenaikan permintaan dengan arah atau besar residual. Residual bervariasi pada seluruh rentang permintaan, dari rendah hingga tinggi, dengan sebaran yang relatif merata. Grafik ini menunjukkan bahwa, model tidak menunjukkan bias atau error sistematis pada fitur permintaan. Artinya, baik permintaan tinggi maupun rendah, model tetap memberikan prediksi yang konsisten. Tidak ada indikasi heteroskedastisitas, yaitu kondisi di mana varians residual berubah tergantung pada nilai fitur. Hal ini sangat penting untuk memastikan bahwa model bekerja stabil di seluruh tingkat permintaan. Hasil ini memperkuat validitas model dalam menangani variasi jumlah permintaan tanpa mengorbankan akurasi prediksi. Grafik ini menjadi bukti tambahan bahwa model Random Forest bekerja dengan baik dalam merespons perubahan pada fitur paling dominan, yaitu permintaan. Tidak adanya pola residual yang mencolok menunjukkan bahwa prediksi yang dihasilkan tidak bias terhadap level permintaan tertentu, menjadikan model lebih andal untuk diterapkan dalam situasi permintaan yang dinamis.

3. ANALISA DAN PEMBAHASAN

Berdasarkan dari penelitian ini yang telah dilakukan dapat disimpulkan beberapa hal berikut:

1. Model *Random Forest* Efektif untuk Prediksi Lama Produksi
 Penelitian berhasil membangun dan melatih model prediksi lama produksi menggunakan algoritma Random Forest. Model ini menunjukkan performa yang sangat baik dengan nilai R^2 sebesar 0.884 dan MSE sebesar 32.64, menandakan akurasi yang tinggi dan kesalahan prediksi yang rendah.
2. Permintaan Produk adalah Faktor Paling Dominan
 Dari hasil analisis feature importance, diketahui bahwa jumlah permintaan memiliki pengaruh terbesar terhadap lama produksi (kontribusi lebih dari 58%), diikuti oleh stok bahan baku dan tenaga kerja.
3. Model Memiliki Generalisasi yang Baik
 Berdasarkan hasil evaluasi melalui kurva pembelajaran (learning curve) dan grafik residual, model menunjukkan kestabilan performa, tidak mengalami overfitting, serta dapat diandalkan untuk digunakan dalam berbagai kondisi permintaan produksi.
4. Visualisasi Analitik Mendukung Interpretasi Model
 Penggunaan *Partial Dependence Plot (PDP)* dan *Scatter Plot* membantu memahami bagaimana setiap variabel mempengaruhi prediksi waktu produksi, serta membuktikan bahwa model bekerja secara konsisten dan tidak bias.

4. KESIMPULAN

Berdasarkan dari hasil penelitian ini, beberapa saran yang dapat diberikan untuk pengembangan lebih lanjut ialah

1. Penambahan Dataset untuk Meningkatkan Akurasi



JRIIN : Jurnal Riset Informatika dan Inovasi
Volume 3, No. 12 Tahun 2026
ISSN 3025-0919 (media online)
Hal 3146-3150

- Disarankan untuk mengumpulkan lebih banyak data historis dengan variasi jenis produk dan kondisi produksi agar model lebih kuat dalam menangani variasi dan meningkatkan ketepatan prediksi.
2. Eksplorasi Algoritma Lain untuk Perbandingan
Walaupun Random Forest terbukti efektif, penelitian selanjutnya sebaiknya membandingkan performanya dengan algoritma lain seperti Gradient Boosting, XGBoost, atau Neural Network untuk mengetahui apakah ada metode lain yang lebih optimal.
 3. Implementasi Langsung dalam Sistem Produksi
Aplikasi prediksi berbasis web menggunakan model ini sebaiknya segera diujicobakan secara langsung dalam operasional PT Elektronik untuk menguji keandalannya dalam kondisi nyata.
 4. Integrasi Data Real-Time
Pengembangan lanjutan dapat mempertimbangkan integrasi data secara real-time dari sistem produksi (misalnya IoT atau ERP) agar estimasi waktu produksi menjadi lebih dinamis dan akurat.
 5. Peningkatan Visualisasi dan UI Aplikasi
Agar aplikasi lebih mudah digunakan oleh pengguna non-teknis, disarankan untuk meningkatkan antarmuka pengguna (UI) dan menyediakan visualisasi prediksi yang lebih intuitif.

REFERENCES

- Abdillah, M. O., Pane, O. A., & Lubis, F. R. A. (2023). Implementasi keamanan aset informasi steganografi menggunakan metode least significant bit (LSB). *Jurnal Sains dan Teknologi (JSIT)*, 3(1), 40–46. <https://doi.org/10.47233/jsit.v3i1.482>
- Andika, D., & Darwis, D. (2022). Modifikasi algoritma GIFShuffle untuk peningkatan kualitas citra pada steganografi. 1(2).
- Anggraeni, E. P., Kartikadewi, A., & Rosyid, L. A. A. (2020). Implementasi kriptografi dengan algoritma.
- Chayes, J. (2021). Leading data science and computing at UC Berkeley. *Harvard Data Science Review*. <https://doi.org/10.1162/99608f92.12c8533a>
- Gupta, A., Goyal, S., & Bhushan, B. (2012). Information hiding using least significant bit steganography and cryptography. *International Journal of Modern Education and Computer Science*, 4(6), 27–34. <https://doi.org/10.5815/ijmecs.2012.06.04>
- Hasugian, P. S., & Simangunsong, A. (2022). Implementation of least significant bit (LSB) algorithm for data security in digital imagery. <http://ejournal.seaninstitute.or.id/index.php/InfoSains>
- Ibnu Daqiqil Id. (2021). Ibnu Daqiqil Id. <https://doi.org/10.5281/zenodo.5113507>
- Islamiyah, M., Subekti, P., Andini, T. D., & Malang, S. A. (2021). Pemanfaatan metode item-based collaborative filtering untuk rekomendasi wisata di Kabupaten Malang. *Jurnal Ilmiah Teknologi Informasi Asia*, 13(2).
- Kasanah, A. N., Pujiyanto, U. (2021). Penerapan teknik SMOTE untuk mengatasi imbalance class dalam klasifikasi objektivitas berita online menggunakan algoritma KNN. 1(3), 196–201.
- Khilda, N. (2020). Evaluasi User Experience Aplikasi SICEPAT Menggunakan Metode Heuristic Evaluation dan UEQ. *Jurnal Sistem Informatika dan Komputer Akuntansi (SIKAP)*, 9(1), 30–37. <https://doi.org/10.33005/sikap.v9i1.416>
- Manfaat Nur, I., & Muntasiroh, L. (2023). Implementasi adaptive synthetic Bernoulli Naïve Bayes untuk mengatasi imbalance class data pada kasus mental health di Indonesia. 1(1). <http://journalnew.unimus.ac.id/index.php/jodi>
- Mantik, J., Wijaya, B. A., Manalu, A. J., Tarigan, B. A., & Silitonga, S. (2021). Steganography text message using LSB and DCT methods. *Jurnal Mantik*, 5(3).
- Mentang, J. J., Rumayar, A. A., Kolibu, F. K. (2021). Hubungan antara kualitas jasa pelayanan kesehatan dengan kepuasan pasien di Puskesmas Taratara Kota Tomohon. *Jurnal KESMAS*, 7(5).
- Najla, G., & Fitrihanah, D. (2020). Penerapan metode regresi linear untuk prediksi penjualan properti pada PT XYZ. *Jurnal Telematika*, 14(2).
- Ngurah, G., Nata, M., & Yudiastra, P. (2020). Konferensi Nasional Sistem & Informatika.
- Pamungkas, N. B., Darwis, D., Nurjayanti, D., & Prastowo, A. T. (2020). Perbandingan algoritma pixel value differencing dan modulus function pada steganografi untuk mengukur kualitas citra dan kapasitas penyimpanan. *Jurnal Informatika*, 20(1).
- Prasojo, B., & Haryatmi, E. (2021). Analisa prediksi kelayakan pemberian kredit pinjaman dengan metode random forest. *Jurnal Nasional Teknologi dan Sistem Informasi*, 7(2), 79–89. <https://doi.org/10.25077/teknosi.v7i2.2021.79-89>



JRIIN : Jurnal Riset Informatika dan Inovasi
Volume 3, No. 12 Tahun 2026
ISSN 3025-0919 (media online)
Hal 3146-3150

- Purwayoga, V., & Nurkholis, A. (2023). Visualisasi rekomendasi pemilihan jurnal bidang informatika dengan menggunakan R dan Shiny. 17(1). <https://ejournal.teknokrat.ac.id/index.php/teknoinfo/index>
- Puspa, S. (2021). Sistem informasi. 6(1).
- Python Software Foundation. (2024). *Python*. <https://www.python.org/>
- Ratnasari, A. P., & Dwiyanto, F. A. (2020). Metode steganografi citra digital. 2(2), 52.
- Retnoningsih, E., & Pramudita, R. (2020). Mengenal machine learning dengan teknik supervised dan unsupervised learning menggunakan Python. *BINA INSANI ICT Journal*, 7(2), 156–165.
- Samosir, F. V. P., Mustamu, L. P., Anggara, E. D., Wiyogo, A. I., & Widjaja, A. (2021). Exploratory data analysis terhadap kepadatan penumpang kereta rel listrik. *Jurnal Teknik Informatika dan Sistem Informasi*, 7(2). <https://doi.org/10.28932/jutisi.v7i2.3700>
- Santoso, B., & Azis, A. I. S. (2020). *Machine learning & reasoning fuzzy logic: Algoritma, manual, Matlab, & RapidMiner*. Deepublish.
- Sari, I. P., Qathrunada, F., Lubis, N., & Anggraini, T. (2021). Perancangan sistem absensi pegawai kantor secara online berbasis website HTML dan CSS.
- Sembiring, S. (2021). Perancangan aplikasi steganografi untuk menyisipkan pesan teks pada gambar dengan metode end of file. <http://www.stmik-budidarma.ac.id>
- Setiawan, A. E., & Pasaribu, A. (n.d.). Penerapan steganografi pada citra digital menggunakan metode least significant bit (LSB) kombinasi RC4 berbasis mobile Android. <http://jti.aisyahuniversity.ac.id/index.php/AJIEE>
- Siduningrum, F. N. H. A., Rizal, A., & Arien, B. D. F. (2020). 10734-40392-1-PB.
- Sijabat, L. H., Syahputri, N. I., & Khairani, M. (2021). Kriptografi dan steganografi penyembunyian pesan pada media audio menggunakan algoritma AES. *Algoritma: Jurnal Ilmu Komputer dan Informatika*, 1.
- Visher, Y. L. J., Susanto, B., & Sasongko, L. R. (2020). Penerapan metode item-based collaborative filtering untuk sistem rekomendasi data MovieLens. <https://ejournal.unsrat.ac.id/index.php/decartesian>
- Wardah, M. I., & Putra, S. D. (2022). Implementasi machine learning untuk rekomendasi film di IMDb menggunakan collaborative filtering berdasarkan analisa sentimen. *Jurnal Manajemen Informatika Jayakarta*, 2(3), 243. <https://doi.org/10.52362/jmijayakarta.v2i3.868>
- Warsito, A. B., Fajarita, L., & Kunci, K. (2021). Proteksi keamanan dokumen sertifikat file JPEG pada perguruan tinggi dengan menggunakan steganografi dan kriptografi. 4(1).
- Yuliana, Y., Firgia, L., & Wati, V. (2022). Implementasi machine learning menggunakan metode case based reasoning untuk diagnosa gizi buruk pada anak. *Jurnal Teknik Informatika dan Komputer (Tekinkom)*, 5(2), 399. <https://doi.org/10.37600/tekinkom.v5i2.563>
- Yusup, I. M., Carudin, C., & Purnamasari, I. (2020). Implementasi algoritma Caesar cipher dan steganografi least significant bit untuk file dokumen. *Jurnal Teknik Informatika dan Sistem Informasi*, 6(3). <https://doi.org/10.28932/jutisi.v6i3.2817>