

## Analisis Performa Metode Extreme Learning Machine dan Multiple Linear Regression dalam Prediksi Produksi Gula

Ahmadi Yuli Ananta<sup>1,\*</sup>, Rudy Ariyanto<sup>1</sup>, Imam Fahrur Rozi<sup>2</sup>, Rakhmat Arianto<sup>3</sup>

<sup>1</sup> Program Studi Sistem Informasi Bisnis, Politeknik Negeri Malang, Indonesia

<sup>2</sup> Program Studi Teknik Informatika, Politeknik Negeri Malang, Indonesia

<sup>3</sup> Program Studi Magister Terapan Rekayasa Teknologi Informasi, Politeknik Negeri Malang, Indonesia

\* Correspondence: ahmadi@polinema.ac.id

**Copyright:** © 2025 by the authors

Received: 22 Februari 2025 | Revised: 4 Maret 2025 | Accepted: 24 Maret 2025 | Published: 15 April 2025

### Abstrak

Gula merupakan komoditas penting di Indonesia dengan permintaan yang terus meningkat setiap tahun. Variasi produksi gula memerlukan strategi prediksi yang akurat untuk perencanaan industri. Penelitian ini bertujuan menganalisa performa metode *Extreme Learning Machine* (ELM) dan *Multiple Linear Regression* (MLR) dalam memprediksi produksi gula. Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan subjek penelitian berupa data produksi gula selama masa giling tahun 2020-2023. Teknik pengumpulan data dilakukan melalui observasi dan dokumentasi, sementara teknik analisis data menggunakan *Mean Absolute Percentage Error* (MAPE) dan *10-Fold Cross-Validation* untuk mengukur akurasi model. Hasil penelitian menunjukkan bahwa ELM memiliki tingkat kesalahan lebih rendah (MAPE 16,06%) dibandingkan MLR (MAPE 27,90%), sehingga lebih efektif dalam menangkap pola produksi gula yang kompleks. Implementasi model ini dalam sistem berbasis web juga memungkinkan pemantauan produksi secara lebih efisien. Metode ELM lebih unggul dalam prediksi produksi gula dan dapat diintegrasikan ke dalam sistem industri untuk mendukung pengambilan keputusan berbasis data. Penelitian selanjutnya dapat mengeksplorasi model prediksi lain, seperti deep learning, serta mempertimbangkan faktor eksternal seperti cuaca dan kondisi tanah untuk meningkatkan akurasi.

**Kata kunci:** gula; prediksi; *extreme learning machine*; mape; *multiple linear regression*

### Abstract

*Sugar is a crucial commodity in Indonesia, with demand increasing annually. Variations in sugar production require accurate prediction strategies for industrial planning. This study aims to analyze the performance of the Extreme Learning Machine (ELM) and Multiple Linear Regression (MLR) methods in predicting sugar production. This research employs a quantitative experimental approach, with sugar production data during the 2020-2023 milling period as the research subject. Data collection techniques involve observation and documentation, while data analysis techniques utilize Mean Absolute Percentage Error (MAPE) and 10-Fold Cross-Validation to measure model accuracy. The results indicate that ELM has a lower error rate (MAPE 16.06%) compared to MLR (MAPE 27.90%), making it more effective in capturing complex sugar production patterns. Implementing this model in a web-based system also enables more efficient production monitoring. The ELM method proves to be superior in predicting sugar production and can be integrated into industrial systems to support data-driven decision-making. Future research can explore other predictive models, such as deep learning, and consider external factors like weather and soil conditions to enhance accuracy.*

**Keywords:** *sugar; prediction; extreme learning machine; mape; multiple linear regression*



## PENDAHULUAN

Gula merupakan salah satu kebutuhan utama konsumsi masyarakat yang sangat penting bagi masyarakat di seluruh Indonesia. Banyak industri, termasuk industri tepung, pengolahan pangan, serta industri pengolahan dan pengawetan pangan menggunakan gula sebagai bahan baku utamanya (Laratiwi et al., 2021; Nugroho et al., 2023). Gula merupakan salah satu produk industri yang menjadi kebutuhan pokok bagi masyarakat Indonesia. Setiap tahun, permintaan gula terus meningkat. Berdasarkan data BPS tahun 2019, konsumsi gula nasional mencapai 5,1 juta ton dan mengalami kenaikan menjadi 5,25 juta ton pada periode 2020-2021 (Haikal et al., 2023). Proyeksi menunjukkan bahwa total konsumsi gula di Indonesia diperkirakan mencapai 25,6 juta ton pada tahun 2025 dan meningkat hingga 29,1 juta ton pada tahun 2045 (Atikasari et al., 2023; Kurniawan & Herwanto, 2022). Perhitungan ini belum mencakup penggunaan gula dalam industri makanan dan minuman, seperti kue, minuman, serta produk olahan lainnya yang menggunakan gula rafinasi dan turunannya (Ridla & Rahma, 2024; Susanto et al., 2022). Dengan demikian, angka konsumsi gula sebenarnya berpotensi lebih tinggi dari estimasi yang telah dibuat (Hutami et al., 2023; Sinuraya et al., 2024). Produksi gula mengalami perubahan dari tahun ke tahun dan menghadapi berbagai tantangan, termasuk keterbatasan lahan, efisiensi produksi, serta faktor lingkungan seperti perubahan iklim yang mempengaruhi hasil panen tebu. Produksi gula nasional belum mampu sepenuhnya memenuhi kebutuhan domestik, sehingga Indonesia masih bergantung pada impor gula untuk menutup defisit produksi. Menurut data Kementerian Perindustrian, produksi gula nasional hanya mampu memenuhi sekitar 60–70% dari total kebutuhan dalam negeri, dengan sisanya harus diimpor dari negara produsen utama seperti Thailand, India, dan Brasil (Hutami et al., 2023; Jaelani, 2022). Ketimpangan antara produksi dan konsumsi ini menuntut adanya strategi prediksi yang lebih akurat guna meningkatkan efisiensi produksi, mengoptimalkan distribusi, serta mengurangi ketergantungan terhadap impor. Variasi produksi dari tahun ke tahun juga menjadi indikator penting dalam merancang kebijakan industri gula yang lebih berkelanjutan. Variasi ini dapat dijadikan indikator dalam merancang strategi untuk memenuhi kebutuhan gula di Indonesia (Heryanto & Suryatmana, 2020). Hal ini membuat prediksi memiliki peranan penting dalam membantu kondisi tersebut.

Solusi yang diusulkan dalam menyelesaikan permasalahan ini, diperlukan pendekatan berbasis teknologi yang mampu menghasilkan prediksi produksi gula dengan tingkat akurasi yang lebih tinggi. Salah satu metode yang dapat diimplementasikan adalah penerapan teknik data mining, yang berfungsi untuk mengeksplorasi serta menganalisis kumpulan data dalam skala besar guna mengidentifikasi pola, tren, dan korelasi yang sebelumnya tidak terdeteksi. Dalam konteks ini, metode prediksi berbasis *Extreme Learning Machine* (ELM) dan *Multiple Linear Regression* (MLR) menjadi alternatif yang prospektif dalam membangun model prediktif terhadap produksi gula. Model ini mempertimbangkan variabel-variabel utama, seperti rendemen tebu, luas areal, jumlah tebu yang diproses, tingkat produktivitas, serta total hasil produksi gula, sehingga dapat meningkatkan efektivitas perencanaan dan pengambilan keputusan dalam industri gula. Dengan menerapkan teknik *data mining*, proses eksplorasi dan analisis terhadap himpunan data berukuran besar dapat dilakukan untuk mengidentifikasi korelasi, tren, serta pola tersembunyi yang sebelumnya tidak terdeteksi. Wawasan ini dapat digunakan untuk pengambilan keputusan yang lebih baik dan untuk memecahkan masalah bisnis yang kompleks. “Teknik, metode atau algoritma di dalam data mining sangat beragam. Dalam jurnal ilmiah, *data mining* sering disebut sebagai *Knowledge Discovery in Database* (KDD). Hasil dari proses *data mining* sangat berharga dalam membantu pengambilan keputusan yang lebih baik di masa depan. Beberapa proses umum yang dilakukan dalam *data mining* antara lain deskripsi, prediksi, estimasi, klasifikasi, *clustering*, dan asosiasi (Habsari et al., 2020). Prediksi dan klasifikasi merupakan dua teknik yang sangat umum digunakan dalam

*data mining* untuk menganalisis data, dengan tujuan untuk mengidentifikasi kelas data atau memprediksi nilai data di masa yang akan datang (Putri et al., 2021).

Penelitian sebelumnya telah membahas penerapan metode prediksi berbasis *machine learning* dan regresi dalam berbagai bidang, termasuk ekonomi, pertanian, harga properti, serta industri kimia. Penelitian yang dilakukan oleh Kertayuga et al. (2021) telah menggunakan algoritma ELM untuk meramalkan ekspor dan impor migas serta nonmigas guna mendukung strategi pembangunan ekonomi di Indonesia. Sementara itu, Rahmadhani et al. (2022) menerapkan ELM dalam memprediksi harga cabai rawit di Kota Malang sebagai langkah preventif bagi konsumen dan pemerintah dalam menghadapi fluktuasi harga. Selain itu, metode regresi juga telah digunakan dalam penelitian lain, seperti yang dilakukan oleh Mu'tashim et al. (2021) dalam analisis harga properti serta penelitian Ridla & Rahma (2024) yang meramalkan hasil panen padi menggunakan regresi linier.

Berbagai penelitian telah membahas penerapan metode prediksi dalam sektor ekonomi dan pertanian, penelitian yang secara spesifik mengaplikasikan metode ini dalam industri gula masih sangat terbatas (Chakravarthy & Rajaguru, 2022). Produksi gula merupakan sektor yang memiliki peran strategis dalam perekonomian nasional dan ketahanan pangan, sehingga kemampuan untuk memprediksi hasil produksi menjadi aspek yang krusial dalam proses pengambilan keputusan industri (Prianda & Widodo, 2021; Rozi et al., 2024). Hingga saat ini, belum ada penelitian yang secara eksplisit membandingkan performa ELM dan MLR dalam memprediksi produksi gula di Indonesia. Oleh karena itu, penelitian ini mengeksplorasi penerapan kedua metode tersebut dalam industri gula, guna menentukan model prediksi yang lebih optimal dan akurat.

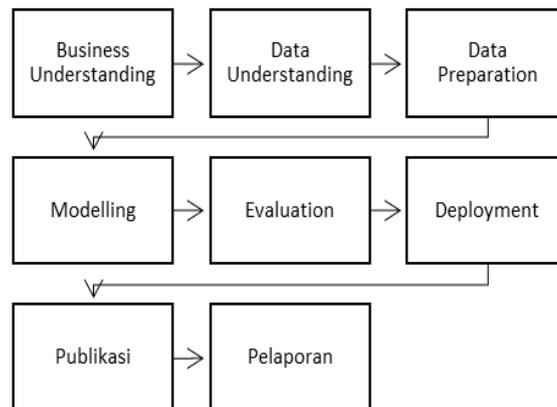
Penelitian ini bertujuan untuk menganalisis performa metode ELM dan MLR dalam memprediksi produksi gula berdasarkan faktor-faktor seperti rendemen tebu, luas areal, jumlah tebu masuk, produktivitas, dan hasil produksi gula, serta menentukan model prediksi yang paling akurat dan aplikatif dalam skala industri guna mendukung pengambilan keputusan strategis. Hasil penelitian ini diharapkan dapat membantu produsen gula dalam perencanaan produksi yang lebih efisien, optimalisasi alokasi sumber daya, serta mitigasi fluktuasi hasil produksi akibat faktor eksternal, seperti perubahan iklim dan ketersediaan bahan baku (Hazizah & Widiyaningtyas, 2024). Selain itu, temuan kami nantinya dapat menjadi dasar bagi pembuat kebijakan dalam merancang strategi ketahanan pangan dan mengurangi ketergantungan terhadap impor gula melalui peningkatan efisiensi produksi dalam negeri, sehingga dapat meminimalkan risiko surplus atau defisit produksi yang berdampak pada stabilitas harga gula di pasar serta meningkatkan efisiensi dan daya saing industri gula dalam skala nasional maupun global.

## **METODE**

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan fokus pada komputasi prediktif untuk menganalisa efektivitas metode ELM dalam prediksi produksi gula. Data historis produksi gula serta variabel terkait dianalisis untuk mengukur sejauh mana metode ini mampu memberikan prediksi yang akurat dan efisien serta mengidentifikasi pola dan hubungan antara faktor-faktor yang memengaruhi produksi gula, sehingga dapat menghasilkan model prediksi yang optimal. Evaluasi dilakukan dengan membandingkan kinerja metode ELM terhadap data historis guna menentukan efisiensi serta keunggulannya dalam analisis produksi gula. Desain alur penelitian digambarkan pada gambar 1.

*Business Understanding* untuk mendapatkan data produksi gula selama periode giling 2020–2023 melalui observasi dan dokumentasi, mencakup rendemen tebu, luas areal, tebu masuk, produktivitas, dan hasil produksi. Sebelum pemodelan, dilakukan data preparation untuk membersihkan, mengubah, dan mengorganisir data agar siap dianalisis menggunakan

metode ELM dan MLR. Evaluasi model dilakukan dengan MAPE untuk menilai akurasi prediksi.



**Gambar 1.** Diagram alir penelitian

Prediksi produksi gula menggunakan MLR dan ELM dengan mempertimbangkan variabel terikat, yaitu jumlah produksi gula (ton), serta beberapa variabel bebas yang memengaruhi. Variabel bebas meliputi rendemen tebu, luas areal, jumlah tebu masuk, produktivitas tebu, serta faktor lingkungan seperti curah hujan dan suhu. MLR dapat dihitung berdasarkan persamaan 1.

$$y = \beta_0 + \beta_1 X_1 + \dots + \beta_n X_n + \varepsilon \quad (1)$$

Persamaan 1 digunakan untuk memodelkan hubungan antara variabel terikat dan variabel bebas dalam prediksi produksi gula. Variabel terikat  $y$  merepresentasikan jumlah produksi gula, sementara  $X_1, X_2, \dots, X_n$  adalah variabel bebas seperti rendemen tebu, luas areal, jumlah tebu masuk, dan produktivitas.  $\beta_0$  merupakan intersep yang menunjukkan nilai awal produksi saat semua variabel bebas bernilai nol, sedangkan  $\beta_1, \beta_2, \dots, \beta_n$ , adalah koefisien regresi yang mencerminkan pengaruh masing-masing variabel bebas terhadap produksi gula.  $\varepsilon$  mewakili galat atau faktor lain di luar model yang dapat memengaruhi hasil prediksi.

Proses pelatihan ELM bertujuan melatih sistem untuk menghasilkan prediksi akurat. Tahapannya mencakup pembangkitan bobot dan bias secara acak dalam rentang tertentu, serta perhitungan output lapisan tersembunyi ( $H$ ) menggunakan fungsi aktivasi. Nilai ( $H$ ) dihitung berdasarkan bobot, bias, dan matriks  $H_{init}$ . Rumus untuk menghitung  $H_{init}$  ditunjukkan pada persamaan 2. Sementara itu persamaan 6 digunakan untuk menghitung nilai output layer.

$$H_{init} = X * W^t \quad (2)$$

Setelah mendapatkan  $H_{init}$ , tahap berikutnya adalah memperoleh *output hidden layer* ( $H$ ) dengan menggunakan fungsi aktivasi. Dalam hal ini, fungsi aktivasi yang diterapkan adalah *sigmoid biner*, seperti yang dinyatakan dalam persamaan 3. Selanjutnya Proses pengujian ELM untuk memvalidasi prediksi dan mengevaluasi algoritma yang telah dilatih tanpa menghitung matriks *Moore-Penrose invers* semu atau bobot keluaran. Langkah-langkahnya mencakup penggunaan bobot dan bias dari pelatihan, perhitungan matriks  $H_{init}$ , output lapisan tersembunyi dengan fungsi aktivasi, serta output lapisan akhir.

$$H(x) = \frac{1}{(1+e^{-x})} \quad (3)$$

Langkah akhir dalam proses pelatihan adalah menghitung nilai pada lapisan output dengan menggunakan persamaan 4. Perhitungan ini berfungsi untuk menyesuaikan bobot dan bias agar model dapat meningkatkan akurasi prediksi. Dengan demikian, model dapat mempelajari pola dari data dan menghasilkan output yang lebih optimal serta sesuai dengan tujuan pembelajaran.

$$O = H * \beta \quad (4)$$

**Keterangan:**

$O$  = Nilai matriks *output layer*

$H$  = Nilai output *hidden layer* menggunakan fungsi aktivasi

$\beta$  = Nilai matriks *output weight*

## HASIL DAN PEMBAHASAN

### Hasil

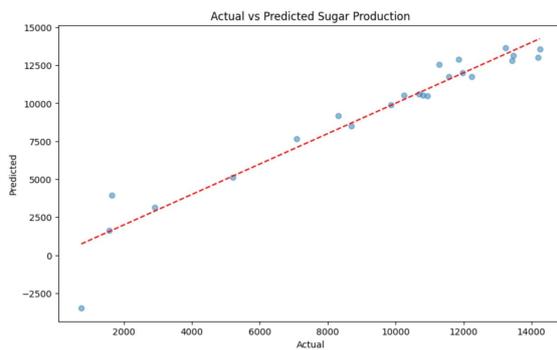
Data yang digunakan di penelitian ini mengacu pada data produksi gula dalam masa giling pada industri gula. Masa giling adalah periode atau musim ketika tanaman tebu dipanen dan diolah menjadi gula di pabrik gula dan masa giling berlangsung beberapa bulan dalam setahun yang tergantung pada iklim dan kondisi pertanian setempat. Data yang diambil adalah data per bulan. Tahap *data understanding* dengan mengumpulkan data per bulan yang memungkinkan pemantauan yang lebih cermat dan responsif terhadap perubahan yang terjadi dalam operasional dan produksi. Untuk tahun 2020 data yang diambil dari bulan Juni-November, tahun 2021 data yang diambil dari bulan Juni-Oktober, tahun 2022 data yang diambil data yang diambil dari bulan Juni-November, dan tahun 2023 data yang diambil dari bulan Mei-Oktober. Sehingga total data yang digunakan adalah 23 baris data bulanan yang diambil selama periode tahun 2020-2023. Pemilihan periode ini penting karena mencerminkan dinamika produksi yang sebenarnya, memungkinkan pemantauan pola produksi secara lebih akurat, serta mengidentifikasi faktor-faktor yang mempengaruhi fluktuasi hasil produksi dari tahun ke tahun.

Pada tahap *pre-processing* dihasilkan data yang sudah dibersihkan, termasuk penanganan nilai yang hilang atau tidak valid serta penyesuaian format data agar lebih konsisten. Data yang dikumpulkan per bulan selama masa giling dikonversi ke dalam bentuk numerik, dengan memastikan bahwa setiap variabel memiliki satuan yang seragam. Selain itu, format desimal disesuaikan agar data lebih akurat dalam perhitungan statistik dan pemodelan sehingga ditetapkan bahwa produksi gula sebagai target dan variabel yang lainnya yang digunakan sebagai penentu hasil produksi gula.

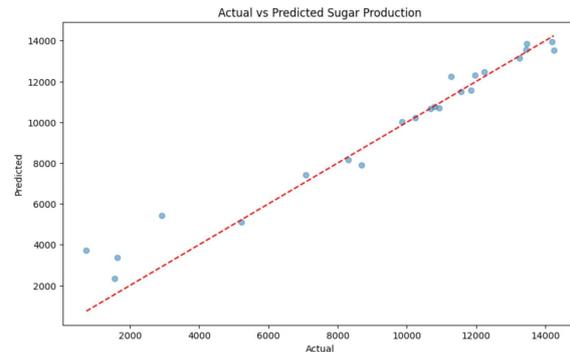
Metode analisis yang digunakan dalam penelitian ini, yaitu ELM dan MLR, diterapkan guna mengetahui performa kedua metode dalam melakukan prediksi pada produksi gula yang menjadi bagian dari penerapan prinsip *k-fold cross validation*, melalui pendekatan ini, sehingga diperoleh pemodelan prediktif yang lebih untuk mengoptimalkan proses analisis data dalam industri gula.

Proses pemodelan dalam penelitian ini, tujuan utamanya adalah memprediksi produksi gula berdasarkan variabel-variabel input yang tersedia dalam dataset. Model yang digunakan dalam penelitian ini adalah MLR dan ELM, yang dianalisis kemampuannya dalam menangani hubungan linier antara variabel-variabel *input* dan *output*. Untuk mengevaluasi model, digunakan teknik 10-Fold Cross-Validation, di mana data dibagi menjadi 10-fold dengan pengacakan (*shuffle=True*) dan pengaturan *random\_state=42* untuk memastikan hasil yang

dapat direproduksi. Dalam setiap fold, data dilatih dan diuji secara terpisah, dan performa model dievaluasi menggunakan beberapa metrik. Hasil dari pemodelan kedua metode yang digunakan dalam prediksi dapat dilihat pada gambar 2 dan 3.



**Gambar 2.** Plot hasil prediksi mlr



**Gambar 3.** Plot hasil prediksi elm

Hasil prediksi model MLR pada gambar 2 menunjukkan keterbatasan dalam memprediksi produksi gula, terutama pada nilai-nilai ekstrem yang jauh dari rata-rata, sehingga menghasilkan kesalahan prediksi yang cukup besar dan inkonsistensi dalam estimasi. Sebaliknya, pada gambar 3, model ELM mampu memberikan prediksi yang lebih akurat dengan titik-titik prediksi yang lebih dekat dengan garis diagonal ideal, meskipun terdapat sedikit *overestimation*. Keunggulan ELM terletak pada kemampuannya menangkap pola kompleks dalam data, sementara MLR lebih terbatas karena hanya mengandalkan hubungan linier antar variabel. Dengan demikian, ELM lebih efektif dalam menghasilkan prediksi yang lebih akurat dibandingkan MLR.

Evaluasi dilakukan dengan membuat metrik evaluasi dengan menggunakan MAPE untuk mengukur rata-rata *error absolut* dalam persentase. Hasil evaluasi untuk setiap *fold* dicatat, termasuk MAPE. Selain itu, rata-rata dan standar deviasi dari semua metrik tersebut dihitung untuk memberikan gambaran umum tentang performa model secara keseluruhan. Prediksi yang dihasilkan oleh model juga dibandingkan dengan nilai aktual, dan hasilnya divisualisasikan dalam bentuk tabel serta plot untuk menunjukkan kesesuaian antara nilai prediksi dan nilai aktual.

**Tabel 1.** Hasil validasi dengan elm

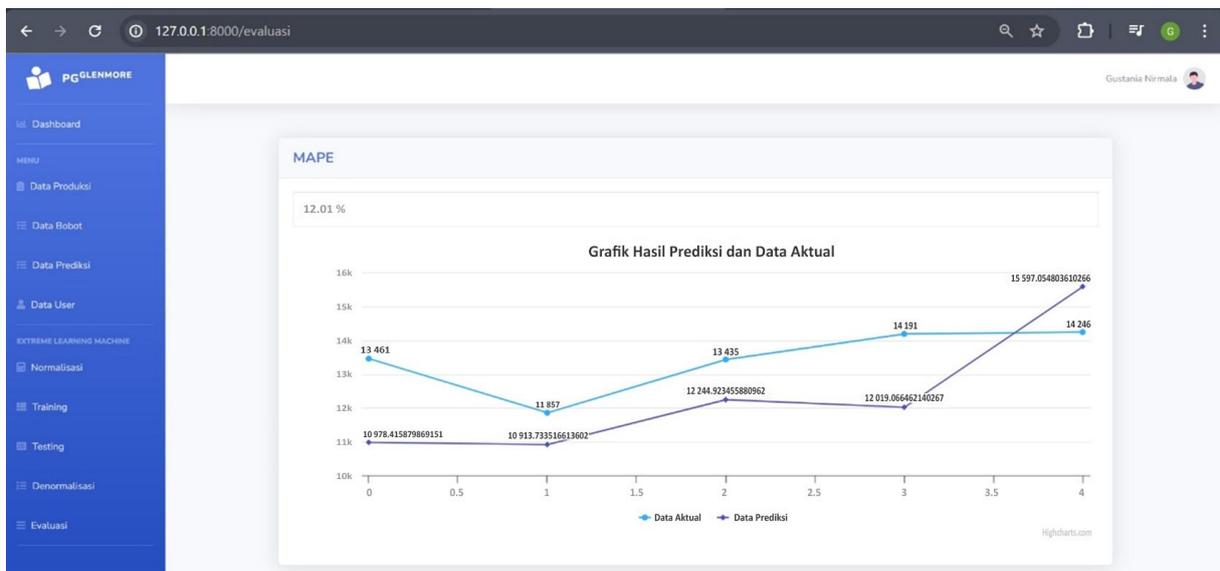
Validasi K-Fold	MAPE (%)
0	2,17%
1	0,75%
2	83,30%
3	1,37%
4	39,86%
5	5,88%
6	6,21%
7	14,26%
8	2,57%
9	4,26%
Rata-rata MAPE	16,06%

Pada tahap evaluasi dalam penelitian ini, kedua model algoritma *data mining*, yaitu ELM dan MLR, dievaluasi menggunakan metode MAPE. MAPE adalah metrik yang digunakan untuk mengukur seberapa besar kesalahan prediksi dari suatu model dalam bentuk persentase,

yang dihitung sebagai rata-rata dari persentase kesalahan absolut antara nilai prediksi dan nilai aktual. Semakin rendah nilai MAPE, semakin baik kinerja model dalam memprediksi data.

**Tabel 2.** Hasil validasi dengan mlr

Validasi K-Fold	MAPE (%)
0	190,07%
1	1,14%
2	51,11%
3	2,79%
4	6,18%
5	2,10%
6	9,74%
7	3,56%
8	3,97%
9	8,31%
Rata-rata MAPE	27,90%



**Gambar 4.** Halaman web perhitungan nilai evaluasi

Model ELM menunjukkan nilai MAPE sebesar 16,06%, yang berarti rata-rata kesalahan prediksi model ini sekitar 16,06% dari nilai aktualnya. Ini menunjukkan bahwa ELM memiliki tingkat akurasi yang cukup baik dalam memprediksi produksi gula, dengan kesalahan prediksi yang relatif rendah. Model MLR memiliki nilai MAPE sebesar 27,90%, yang berarti rata-rata kesalahan prediksi model ini sekitar 27,90% dari nilai aktualnya. Nilai ini lebih tinggi dibandingkan dengan ELM, menunjukkan bahwa MLR memiliki tingkat akurasi yang lebih rendah dan kesalahan prediksi yang lebih besar. Berdasarkan nilai MAPE, ELM memiliki kinerja yang lebih baik dalam hal akurasi prediksi dibandingkan dengan MLR. Dengan MAPE yang lebih rendah, ELM lebih mampu menghasilkan prediksi yang mendekati nilai aktual dalam konteks prediksi produksi gula, yang dipengaruhi aspek atau variabel utama yang menonjol dalam prediksi produksi gula meliputi jumlah bahan baku, luas lahan, rendemen tebu, produktivitas, dan hasil produksi gula yang berperan penting karena secara langsung mempengaruhi jumlah gula yang dapat diproduksi dalam suatu periode tertentu. Misalnya, rendemen tebu menunjukkan persentase gula yang dihasilkan dari jumlah tebu yang digiling, sehingga menjadi faktor kunci dalam menentukan produksi gula secara keseluruhan. Luas areal

tebu juga berkontribusi terhadap total produksi, karena semakin luas lahan yang ditanami, semakin besar potensi hasil panennya.

Selanjutnya setelah melalui tahap evaluasi, model ELM menunjukkan keluaran hasil yang lebih baik dibandingkan dengan MLR dalam hal akurasi prediksi. Nilai MAPE untuk ELM adalah 16,06%, sementara MLR memiliki MAPE sebesar 27,90%. Angka MAPE yang lebih rendah pada ELM mengindikasikan bahwa model ini lebih akurat dalam memprediksi nilai produksi gula, dengan kesalahan prediksi yang lebih kecil dibandingkan dengan MLR. Dengan mempertimbangkan hasil evaluasi ini, langkah selanjutnya adalah menerapkan model ELM dalam fase *deployment*.

Fase *deployment* dengan menerapkan model ELM yang telah dievaluasi ke dalam bentuk prototipe aplikasi berbasis web. Aplikasi ini dirancang sebagai alat bantu bagi pengguna untuk memantau dan memprediksi produksi gula secara lebih efisien. Hasil implementasi pada halaman nilai evaluasi digunakan untuk menampilkan nilai evaluasi *error* MAPE yang dihasilkan dalam metode ELM ditunjukkan pada gambar 4.

## Pembahasan

Berdasarkan hasil penelitian, penggunaan metode ELM dan MLR dalam prediksi produksi gula menunjukkan perbedaan kinerja yang signifikan. Evaluasi menggunakan MAPE menunjukkan bahwa ELM memiliki nilai kesalahan lebih rendah dibandingkan MLR. Perbedaan ini menunjukkan bahwa ELM lebih mampu menangkap pola produksi gula yang kompleks dan dinamis, sementara MLR yang bergantung pada hubungan linier mengalami keterbatasan dalam menangani data dengan pola yang lebih kompleks.

Proses pengolahan data diawali dengan *pre-processing* untuk memastikan data bersih, terstruktur, dan siap digunakan dalam model prediksi. *Dataset* yang dianalisis mencakup data produksi gula dari 2020 hingga 2023, dengan variabel utama seperti rendemen tebu, luas areal, jumlah tebu masuk, produktivitas, dan hasil produksi gula. Evaluasi model dilakukan menggunakan *10-Fold Cross-Validation* untuk meningkatkan keandalan prediksi. Hasil menunjukkan bahwa ELM lebih akurat dan stabil dibandingkan MLR, yang cenderung mengalami penyimpangan lebih besar. Di antara variabel yang digunakan, rendemen tebu menjadi faktor kunci karena menentukan jumlah gula yang dapat diekstrak. Luas areal dan jumlah tebu masuk berperan dalam kapasitas produksi, sementara produktivitas tebu mencerminkan efisiensi panen. Dengan mempertimbangkan faktor-faktor ini, model prediksi dapat membantu industri gula dalam perencanaan produksi yang lebih akurat dan optimal.

Penelitian sebelumnya secara umum menggunakan metode MLR atau model regresi konvensional lainnya, yang memiliki keterbatasan dalam menangani hubungan *non-linear* antar variabel (Mu'tashim et al., 2021). Penelitian kami menunjukkan bahwa ELM memiliki keunggulan dalam menangani kompleksitas data produksi gula, sebagaimana dibuktikan oleh nilai MAPE yang lebih rendah dibandingkan MLR. Evaluasi model menggunakan *10-fold cross-validation* juga meningkatkan reliabilitas hasil prediksi dibandingkan pendekatan terdahulu yang cenderung mengandalkan metode validasi sederhana (Kertayuga et al., 2021; Prianda & Widodo, 2021). Selain itu, penelitian kami tidak hanya mengembangkan model prediksi, tetapi juga mengimplementasikannya dalam bentuk *prototipe* aplikasi berbasis web yang memungkinkan industri gula memanfaatkan teknologi ini dalam perencanaan produksi secara *real-time* (Chakravarthy & Rajaguru, 2022), sehingga meningkatkan akurasi prediksi produksi gula, sekaligus memberikan solusi berbasis teknologi yang dapat diterapkan dalam skala industri guna meningkatkan efisiensi operasional dan pengambilan keputusan strategis.

## SIMPULAN

Hasil penelitian ini menunjukkan bahwa ELM memiliki keunggulan dalam akurasi prediksi produksi gula dibandingkan MLR, sebagaimana dibuktikan dengan nilai MAPE yang

lebih rendah. Hal ini menunjukkan bahwa ELM lebih efektif dalam menangani pola data yang kompleks, sedangkan MLR cenderung menghasilkan tingkat kesalahan yang lebih tinggi. Implikasi utama dari temuan ini adalah bahwa ELM dapat diterapkan sebagai metode unggulan dalam industri gula, membantu meningkatkan efisiensi perencanaan produksi berbasis data. Dengan integrasi model prediksi ke dalam sistem berbasis web, pemantauan produksi dapat dilakukan secara lebih akurat dan efisien, memungkinkan pengambilan keputusan yang lebih cepat dan tepat. Temuan ini juga membuka peluang bagi pengembangan lebih lanjut dalam penerapan model prediksi yang lebih adaptif, termasuk dengan mempertimbangkan faktor eksternal seperti kondisi iklim dan kebijakan industri, guna meningkatkan keberlanjutan dan efisiensi industri gula di masa mendatang..

## REFERENSI

- Atikasari, L., Hartini, H., & Harahap, S. (2023). Evaluasi Hasil Trend Produktivitas Tebu (*Saccharum Officinarum* L.) Berdasarkan Kategori Tanam Di PG Semboro PT Perkebunan Nusantara XI: *AGRIBIOS*, 21(2), 172–182. <https://doi.org/10.36841/agribios.v21i2.3664>
- Chakravarthy, S. S., & Rajaguru, H. (2022). Automatic detection and classification of mammograms using improved extreme learning machine with deep learning. *Irbm*, 43(1), 49–61. <https://doi.org/10.1016/j.irbm.2020.12.004>
- Habsari, H. D. P., Purnamasari, I., & Yuniarti, D. (2020). Forecasting Uses Double Exponential Smoothing Method And Forecasting Verification Uses Tracking Signal Control Chart (Case Study: Ihk Data Of East Kalimantan Province). *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 14(1), 013–022. <https://doi.org/10.30598/barekengvol14iss1pp013-022>
- Haikal, F. M., Akrom, M., & Trisnapradika, G. A. (2023). Perbandingan Algoritma Multilinear Regression dan Decision Tree Regressor dalam Memprediksi Efisiensi Penghambatan Korosi Piridazin. *Edumatic: Jurnal Pendidikan Informatika*, 7(2), 307–315. <https://doi.org/10.29408/edumatic.v7i2.22127>
- Hazizah, C. Y., & Widiyaningtyas, T. (2024). Analisis Metode Collaborative Filtering menggunakan KNN dan SVD++ untuk Rekomendasi Produk E-commerce Tokopedia. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 595–604. <https://doi.org/10.29408/edumatic.v8i2.27793>
- Heryanto, M. A., & Suryatmana, E. R. (2020). Dinamika Agroindustri Gula Indonesia: Tinjauan Analisis Sistem. *Jurnal Agribisnis Dan Sosial Ekonomi Pertanian UNPAD*, 5(2), 194–210. <https://doi.org/10.24198/agricore.v5i2.32100>
- Hutami, R., Pribadi, M. F. I., Nurcahali, F., Septiani, B., Andarwulan, N., Sapanli, K., Zuhud, E. A. M., Al Manar, P., Ichsan, N., & Wahyudi, S. (2023). Proses Produksi Gula Aren Cetak (*Arenca pinnata*, Merr) Di Indonesia. *Jurnal Ilmiah Pangan Halal*, 5(2), 119–130. <https://doi.org/10.30997/jiph.v5i2.10237>
- Jaelani, T. (2022). Machine Learning untuk Prediksi Produksi Gula Nasional. *JMPM (Jurnal Material Dan Proses Manufaktur)*, 6(1), 31–36. <https://doi.org/10.18196/jmpm.v6i1.14897>
- Kertayuga, D., Santoso, E., & Hidayat, N. (2021). Prediksi Nilai Ekspor Impor Migas Dan Non-Migas Indonesia Menggunakan Extreme Learning Machine (ELM). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 5(6), 2792–2800.
- Kurniawan, M. H., & Herwanto, D. (2022). Penerapan Metode Double Exponential Smoothing dan Moving Average pada Peramalan Permintaan Produk Gasket Cap di PT. Nesinak Industries. *Serambi Engineering*, VII(1), 2537–2546. <https://doi.org/10.32672/jse.v7i1.3709>

- Laratiwi, B. N., Mulyanto, T., & Yamin, M. (2021). Analisis Produktivitas Produksi Gula Aren Dan Gula Kelapa Di PT X Menggunakan Metode Multi Factor Productivity Measurement Model (MFPMM). *Jurnal Ilmiah Teknologi Dan Rekayasa*, 26(1), 46–55. <https://doi.org/10.35760/tr.2021.v26i1.3531>
- Mu'tashim, M. L., Damayanti, S. A., Zaki, H. N., Muhayat, T., & Wirawan, R. (2021). Analisis Prediksi Harga Rumah Sesuai Spesifikasi Menggunakan Multiple Linear Regression. *JURNAL INFORMATIK*, 3(17), 238–245. <https://doi.org/10.52958/iftk.v17i3.3635>
- Nugroho, B. W. D., Jakti, N. J. K., Rochman, M. A. N., & Nugroho, A. J. (2023). Analisis Pengendalian Kualitas Produk Gula Dan Biaya Kualitas Dalam Menunjang Efektivitas Produksi. *Jurnal Teknologi Dan Manajemen Industri Terapan*, 2(2), 72–81. <https://doi.org/10.55826/tmit.v2i2.100>
- Prianda, B. G., & Widodo, E. (2021). Perbandingan Metode Seasonal Arima Dan Extreme Learning Machine Pada Peramalan Jumlah Wisatawan Mancanegara Ke Bali. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 15(4), 639–650. <https://doi.org/10.30598/barekengvol15iss4pp639-650>
- Putri, S. U., Irawan, E., Rizky, F., Tunas Bangsa, S., -Indonesia Jln Sudirman Blok No, P. A., & Utara, S. (2021). Implementasi Data Mining Untuk Prediksi Penyakit Diabetes Dengan Algoritma C4.5. *KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)*, 2(1), 39–46.
- Rahmadhani, S. N., Logiandani, L., Ramadhan, R. Z., Sofia Amriza, R. N., & Fathoni, M. Y. (2022). Analisis Forecasting Penjualan Gula Merah di Jatilawang Menggunakan Metode Weighted Moving Average. *Jurnal Sisfokom (Sistem Informasi Dan Komputer)*, 11(3), 381–386. <https://doi.org/10.32736/sisfokom.v11i3.1433>
- Ridla, M. A., & Rahma, E. N. (2024). Prediksi Produksi Gula Tebu Berdasarkan Kualitas Menggunakan Metode Neural Network. *Jurnal Janitra Informatika Dan Sistem Informasi*, 4(1), 54–61.
- Rozi, I. F., Arianto, R., Yunianto, D. R., Ananta, A. Y., Rahmawati, S., & Krismawati. (2024). Enhancing Aspect-Based Sentiment Analysis for Radio Station Public Opinion: Evaluating Preprocessing Strategies and Imbalanced Data Handling. *International Conference on Electrical and Information Technology (IEIT)*, 103–108. Malang, Indonesia: IEEE. <https://doi.org/10.1109/IEIT64341.2024.10763129>
- Sinuraya, J. F., Suryana, E. A., Shaffitri, L. R., Suharyono, S. R., & Hermawan, H. R. (2024). Kinerja Industri dan Dinamika Kebijakan Komoditas Gula Kristal Putih Nasional. *Indonesian Sugar Research Journal*, 4(2), 68–79. <https://doi.org/10.54256/isrj.v4i2.129>
- Susanto, V. P., Gunawan, I., & Hartanti, L. P. S. (2022). Aplikasi teorema bayes dalam mendukung aktivitas autonomous maintenance di pabrik gula Kedawoeng. *Agrointek : Jurnal Teknologi Industri Pertanian*, 16(3), 373–384. <https://doi.org/10.21107/agrointek.v16i3.13533>