



Optimasi Parameter Extreme Learning Machine pada Prediksi Penjualan Kopi Guna Efisiensi Stok UMKM

Optimizing Extreme Learning Machine Parameters in Coffee Sales Prediction for MSME Stock Efficiency

Heribertus Ary Setyadi^{1*}, Pudji Widodo², Supriyanta¹

¹Fakultas Teknik dan Informatika, Sistem Informasi, Universitas Bina Sarana Informatika, Surakarta, Indonesia

Jl. Letjen Sutoyo No.43, Cengklik, Nusukan, Kec. Banjarsari, Kota Surakarta, Jawa Tengah, Indonesia

²Fakultas Teknik dan Informatika, Teknologi Komputer, Universitas Bina Sarana Informatika, Banyumas, Indonesia

Jl. Profesor DR. HR Boenjamin No.106, Sumampir Wetan, Pabuaran, Kec. Purwokerto Utara, Kabupaten Banyumas, Jawa Tengah, Indonesia

Email: ^{1*}heribertus.hbs@bsi.ac.id, ²pudji.piw@bsi.ac.id, ³supriyanta.spt@bsi.ac.id

Email Penulis Korespondensi: heribertus.hbs@bsi.ac.id

Received: 03/02/2026, Revised: 11/04/2026, Accepted: 27/08/2026, Published: 23/10/2026

Abstrak—Kedai Kopi Pait Karanganyar belum menerapkan teknik peramalan yang terstruktur guna mengestimasi dan memprediksi permintaan produk kopi. Dua penelitian terdahulu menggunakan Extreme Learning Machine (ELM) untuk peramalan yang berbeda, keduanya menyimpulkan bahwa metode ELM menawarkan akurasi unggul dan efisiensi waktu komputasi. Sementara itu, penelitian terpisah yang meramalkan penjualan jins dengan model ARIMA hanya mencatat akurasi 17,05% berdasarkan indikator MAPE (Mean Absolute Percentage Error). Metode LSTM untuk prediksi siklus menstruasi mencatatkan nilai MAPE sebesar 7,5%. Pemilihan metode ELM dalam riset ini utamanya didasari oleh dua keunggulan yang dilaporkan dalam studi sebelumnya. Penelitian ini mengimplementasikan algoritma ELM (jaringan saraf tiruan) untuk membantu peramalan penjualan minuman kopi. Metode ELM sendiri tersusun atas input layer, output layer, dan sebuah hidden layer penghubung. Sebanyak 215 sampel data penjualan harian selama satu bulan digunakan sebagai himpunan data uji dalam riset ini. Data tersebut dikumpulkan di Kedai Kopi Pait dari April hingga Oktober 2025. Berdasarkan hasil analisis nilai galat menggunakan metode MAPE, diperoleh nilai galat rata-rata sebesar 1,06%. Selanjutnya, perbandingan antara data asli dan data hasil prediksi menunjukkan bahwa nilai MAPE rata-rata untuk konfigurasi jumlah fitur dan neuron tersembunyi yang optimal adalah 3,39%. Dengan konfigurasi terbaik ini, diperoleh tingkat error yang diukur menggunakan perhitungan MAPE sebesar 3,39%. Penelitian ini berkontribusi dalam menyediakan model peramalan inventaris yang efisien bagi pelaku UMKM kedai kopi retail untuk meminimalkan risiko pemborosan bahan baku secara akurat.

Kata Kunci: Extreme Learning Machine; Jaringan Saraf Tiruan; Minuman Kopi; Penjualan; Prediksi

Abstract—Pait Karanganyar Coffee Shop does not currently implement a structured forecasting technique to accurately estimate and predict demand for its coffee products. Prior studies demonstrate that the Extreme Learning Machine (ELM) method offers superior accuracy and highly efficient computation time compared to traditional models. For instance, a separate study using ARIMA achieved a Mean Absolute Percentage Error (MAPE) of 17.05%, while Long Short-Term Memory (LSTM) recorded a 7.5% MAPE. Based on these advantages, the ELM algorithm was selected for this study. This research utilizes this artificial neural network method to assist in predicting daily coffee beverage sales. Structurally, the ELM model is comprised of an input layer, an output layer, and a single connecting hidden layer. A dataset containing 215 daily sales data samples was collected at Pait Coffee Shop from April to October 2025 for testing purposes. The results and error values analysis using the MAPE method demonstrated an initial average error of 1.06%. Furthermore, a rigorous comparison between the actual and predicted data revealed that the optimal configuration of input features and hidden neurons achieved an average MAPE value of 3.39%. Ultimately, this research contributes to providing an efficient inventory forecasting model for retail coffee shop MSMEs to accurately minimize raw material waste. With this best configuration, an error rate measured using MAPE calculation was 3.39%. This research contributes to providing an efficient inventory forecasting model for retail coffee shop MSMEs to minimize raw material waste accurately.

Keywords: Artificial Neural Network; Coffee Beverage; Extreme Learning Machine; Forecasting; Sales

1. PENDAHULUAN

Sebagai salah satu negara penghasil kopi terbaik di Asia, Indonesia memiliki keragaman empat jenis kopi yang dikenal luas, yakni kopi Arabika, Robusta, Liberika, dan Ekselsa. Kopi Arabika dan kopi Robusta merupakan jenis kopi paling populer karena nilainya yang tinggi dalam pasar perdagangan kopi [1]. Beberapa wilayah di Indonesia yang terkenal sebagai penghasil kopi adalah Jawa, Jambi, Lampung, Aceh, Flores, dan Toraja [2]. Di antara komoditas perkebunan lainnya, kopi memiliki nilai ekonomi yang tinggi dan merupakan penyumbang devisa yang signifikan bagi negara. Data ICO per April 2024 menunjukkan bahwa Indonesia menempati posisi kedua sebagai produsen kopi di Asia Pasifik, setelah Vietnam [3].

Menghabiskan waktu bersama sambil minum kopi telah menjadi tradisi di masyarakat Indonesia untuk mempererat kebersamaan dan persaudaraan. Tradisi ini kemudian berkembang menjadi peluang usaha dengan maraknya pembukaan kedai kopi [4]. Tren nongkrong di kalangan pemuda mendorong pesatnya pertumbuhan

bisnis ini di Indonesia, terutama di Surakarta. Seiring waktu, semakin banyak pengusaha yang termotivasi untuk membuka kedai kopi, sehingga keberadaannya semakin mudah ditemukan [5]. Sebagai negara produsen, Indonesia menempati urutan kedua di dunia untuk tingkat konsumsi kopi tertinggi [6].

Estimasi penjualan diperlukan dalam penyusunan rencana produksi, pengadaan bahan baku, dan material lainnya. Perkiraan ini juga bermanfaat untuk menentukan harga produk dan mengoptimalkan keuntungan. Sementara itu, *sortilege* didefinisikan sebagai kegiatan memprediksi suatu peristiwa di masa mendatang yang berfungsi sebagai instrumen perencanaan [7]. Sebuah proses prediksi dapat membantu perusahaan membuat keputusan bisnis, seperti menentukan level inventaris yang paling efisien dan mengelola stok untuk menekan risiko kesalahan perencanaan seminimal mungkin [8]. Perkiraan penjualan dapat dilakukan dengan membuat model perhitungan berdasarkan data penjualan terdahulu [9]. Saat ini, kedai kopi Pait Karanganyar belum menerapkan metode peramalan yang terstruktur untuk mengantisipasi permintaan produk minuman kopi. Proses peramalan hanya mengandalkan data permintaan sebelumnya atau intuisi semata. Kondisi ini berisiko membuat manajemen operasional berjalan tidak efisien dan efektif. Oleh sebab itu, peramalan penjualan harus dilakukan melalui analisis terstruktur untuk menghasilkan estimasi yang tepat. Penelitian ini menggunakan metode Artificial Neural Network (ANN) dengan algoritma Extreme Learning Machine (ELM) untuk membantu memprediksi penjualan minuman kopi [10].

Jaringan Syaraf Tiruan atau ANN merupakan cabang dari pembelajaran mesin. ANN adalah teknik yang dipakai untuk menciptakan program cerdas melalui pemodelan yang meniru fungsi jaringan saraf di otak manusia. ELM adalah metode ANN feed-forward yang hanya terdiri dari satu lapisan tersembunyi, atau disebut juga single-hidden layer feed-forward neural network [11]. Metode pembelajaran ELM dibuat untuk mengatasi kelemahan jaringan saraf feed-forward, khususnya terkait kecepatan belajarnya. Algoritma jaringan saraf dengan satu lapisan tersembunyi ini menghitung bobot keluaran melalui metode kuadrat terkecil [12]. Berbeda dengan algoritma berbasis gradien konvensional seperti backpropagation, di mana semua parameter ANN feed-forward (bobot masukan dan bias tersembunyi) harus ditetapkan secara manual [13]. Keterkaitan antarlapisan parameter ini mengakibatkan kecepatan pembelajaran yang lambat dan risiko terjebak dalam local minima. ELM memilih parameter bobot masukan dan bias tersembunyi secara acak. Hasilnya, proses pembelajaran ELM menjadi cepat dan kinerja generalisasinya baik [14]. Metode ELM juga menawarkan model matematis yang lebih simpel dan efektif dibandingkan metode jaringan saraf tiruan feed-forward konvensional [15].

Beberapa studi terdahulu telah mengkaji prediksi penjualan dan ELM. Sebagai contoh, penelitian [16] yang memprediksi jumlah pembelian di kedai kopi Surabaya menggunakan CatBoost dengan leave one out cross validation. Studi ini memakai pendekatan kuantitatif dan solusi baru untuk mengembangkan aplikasi prediksi pembelian berbasis pembelajaran mesin sekaligus strategi peningkatan volume pembelian untuk tiga kedai kopi di Surabaya. Model CatBoost (MAE 0,91; MAPE 15%) mengungguli LightGBM (MAE 1,13; MAPE 18%), menunjukkan keefektifan dan akurasi CatBoost dalam memprediksi volume pembelian serta mengidentifikasi target pasar industri kedai kopi. Penelitian oleh [17] bertujuan membandingkan metode ELM dan SVR dalam memprediksi harga saham empat bank terbesar di Indonesia, menggunakan himpunan data aktual dari Yahoo Finance. Evaluasi performa dilakukan dengan membandingkan nilai MAPE. Hasil studi menunjukkan bahwa kedua metode tersebut efektif. Namun, ELM unggul dalam efisiensi waktu komputasi, dengan rata-rata 0,006 detik, jauh lebih cepat dibandingkan SVR yang mencapai rata-rata 0,694 detik. Riset yang dilakukan [18] menganalisis Indeks Harga Grosir (HGI) India dan mengusulkan strategi peramalan yang tepat menggunakan pendekatan ELM. Pengelompokan HGI menunjukkan adanya variasi tren dan karakteristik pada enam puluh item makanan dalam kategori 'manufaktur produk makanan'. Metode ELM yang diajarkan mencapai akurasi tertinggi (sekitar 87%) dan mengungguli metode lain dalam perbandingan nilai MAPE dan RMSE. Studi ini menyimpulkan bahwa ELM adalah metode yang efektif untuk meramalkan keenam puluh indeks tersebut. Permata dan Habibi menghasilkan sebuah studi untuk meramalkan penjualan celana jeans memakai model ARIMA. Dengan data penjualan 2018-2022, diperoleh model ARIMA(3, 1, 1) dan ARIMA(2, 1, 0). Akurasi peramalan diukur dengan MAPE dan menghasilkan nilai 17,05% [19]. Sebagai perbandingan, penelitian lain tentang prediksi siklus menstruasi dengan metode LSTM menghasilkan nilai MAPE 7,5% [20].

Kesenjangan penelitian (research gap) dalam studi ini diidentifikasi melalui dua aspek utama. Pertama, sebagian besar literatur peramalan retail tradisional masih mengandalkan model linier seperti ARIMA yang kurang adaptif terhadap pola data penjualan harian kedai kopi retail lokal yang bersifat non linier dan fluktuatif. Kedua, penelitian berbasis ELM terdahulu umumnya berfokus pada ranah finansial makro atau data agregat besar dan sering kali mengabaikan pencarian kombinasi parameter arsitektur secara eksperimental. Penelitian ini mengisi kesenjangan tersebut dengan menerapkan algoritma ELM secara spesifik pada Kedai Kopi Pait Karanganyar, serta melakukan analisis kombinasi terstruktur antara variasi jumlah fitur masukan, jumlah hidden neuron, dan jumlah epoch untuk menekan nilai galat hingga titik minimum.


Berdasarkan kesenjangan tersebut, penelitian ini memiliki dua tujuan utama, yaitu mengevaluasi performa prediksi metode ELM menggunakan metrik MAPE, serta mengidentifikasi konfigurasi arsitektur jaringan terbaik dari parameter-parameter yang diuji. Kontribusi utama dari penelitian ini mencakup dimensi praktis dan teoritis. Secara praktis, studi ini mentransformasi metode intuisi pengusaha mikro menjadi keputusan berbasis data untuk pengadaan bahan baku yang presisi guna menghindari understocking atau overstocking. Secara teoritis, penelitian

ini menyumbang referensi empiris baru mengenai fenomena overfitting akibat penambahan hidden neuron pada pemrosesan data runtun waktu berskala lokal.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian


Metodologi yang diusulkan dimulai dari pengumpulan data terkait penjualan minuman di kedai kopi Pait. Data ini diolah menggunakan metode ELM untuk menghasilkan prakiraan penjualan. Prediksi yang dihasilkan menjadi dasar penentuan pasokan bahan baku. Terakhir, dilakukan penilaian kesalahan terhadap hasil tersebut untuk memastikan tingkat kesalahan yang dihasilkan diminimalkan/optimalkan. Metodologi yang terstruktur dapat memastikan pelaksanaan penelitian berjalan lancar dan efektif. Kerangka prosedural yang dirujuk dalam penelitian ini diilustrasikan pada Gambar 1.



Gambar 1. Kerangka Prosedural Penelitian

2.2 Tahapan Penelitian

Penelitian ini mengumpulkan data primer dengan cara wawancara langsung bersama pemilik kedai kopi Pait di Karanganyar, meminta data penjualan yang mencakup periode April hingga Oktober 2025. Dalam membangun sistem prediksi penjualan minuman kopi, digunakan metode ELM yang merupakan pengembangan dari model ANN. Metode ini mengadopsi arsitektur SLFNs yang mengandalkan satu lapisan tersembunyi di antara lapisan masukan dan keluaran. Data masukan yang digunakan terdiri dari variabel fitur X-1 sampai X-4 serta variabel target T sebagai landasan pemrosesan informasi. Setiap neuron masukan terhubung ke neuron tersembunyi melalui bobot dan bias acak. Arsitektur jaringan metode ELM disajikan pada Gambar 2.



Gambar 2. Arsitektur Jaringan Metode ELM

Sesuai dengan Gambar 2, metode ELM tersusun atas lapisan masukan dan keluaran yang saling terhubung melalui lapisan tersembunyi. Prosesnya dimulai dengan prapemrosesan (preprocessing), tahap krusial dalam penggalian data (data mining) untuk mengolah data mentah [21]. Prapemrosesan pada ELM meliputi pembentukan fitur, yaitu pengelompokan data masukan beserta nilai targetnya, yang kemudian dinormalisasi menggunakan persamaan berikut:

$$V' = \frac{v - \min}{\max - \min} \quad (1)$$

Untuk mendapatkan pola atau formula keluaran metode pembelajaran ELM, yang dinamakan bobot keluaran (β), proses dilakukan pada lapisan tersembunyi [22], [23], [24]. Langkah-langkahnya adalah sebagai berikut:

1. Setelah beberapa fitur masukan ditetapkan, Tahap berikutnya melibatkan inisialisasi bobot masukan (w) dan bias (β) secara acak dalam rentang -1 hingga +1, atau 0 hingga 1. Parameter bobot dan bias ini berfungsi untuk menghubungkan data dari lapisan masukan ke keluaran neuron pada lapisan tersembunyi.
2. Perhitungan nilai H_{init} (hidden neuron output value) didasarkan pada nilai bobot dan bias acak yang sudah ditetapkan. Proses kalkulasi H_{init} menggunakan persamaan berikut:

$$H_{init} = (\sum_{k=1}^n W_{jk} \cdot X_{ik}) + b_j \quad (2)$$

3. Fungsi aktivasi dihitung dari hasil H_{init} . Nilai output fungsi aktivasi dinotasikan sebagai $H(x)$. Untuk menghitung keluaran dari neuron tersembunyi, digunakan fungsi aktivasi sigmoid biner berdasarkan persamaan 3.

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

4. Matriks keluaran lapisan tersembunyi (H_{init}) dengan fungsi aktivasi sigmoid $H(x)$ ditranspos. Hasil transpos ini dilambangkan sebagai H^T .
5. Dilakukan perkalian antara matriks hasil transposisi (H^T) dan matriks keluaran lapisan tersembunyi yang telah diproses fungsi aktivasi sigmoid ($H(x)$).
6. Prosedur inversi terhadap matriks hasil perkalian H^T dan $H(x)$ menerapkan teknik OBE, di mana elemen matriks digantikan hingga membentuk matriks identitas baru. Setelah matriks invers diperoleh, nilai tersebut dikalikan dengan hasil transpos dari keluaran lapisan tersembunyi dengan mengikuti persamaan:

$$H^+ = (H^T \cdot H_{(x)})^{-1} \cdot H^T \quad (4)$$

7. Tahap terakhir adalah memperoleh nilai keluaran metode ELM dengan mengalikan hasil proses invers umum Moore-Penrose dengan nilai target untuk menghitung bobot keluaran (β).

$$\beta = H^+ \cdot T \quad (5)$$

Metode MAPE digunakan untuk mengevaluasi akurasi dengan menghitung rata-rata absolut persentase kesalahan. Rentang nilai MAPE ditampilkan pada Tabel 1.

Tabel 1. Range MAPE

Nilai MAPE	Akurasi Prediksi
< 10%	Sangat akurat
10% - 20%	Akurat
20% - 50%	Cukup akurat
> 50%	Tidak akurat

3. HASIL DAN PEMBAHASAN

3.1 Data Latih

Sebanyak 215 sampel data sekunder digunakan sebagai bahan uji (test material) dalam penelitian ini. Data tersebut merupakan catatan penjualan harian kedai kopi Pait yang dikumpulkan dari April hingga Oktober 2025, yang berfungsi sebagai data masukan. Rincian dataset dapat dilihat pada Tabel 2.

Tabel 2. Data Penjualan April Sampai Oktober 2025

No	Tanggal	Jumlah
1	01/04/2025	53
2	01/04/2025	38
3	01/04/2025	45
4	01/04/2025	71
5	01/04/2025	77
6	02/04/2025	27
7	02/04/2025	73
8	02/04/2025	51
...	...	...
215	31/10/2025	72

Data masukan untuk dataset dibatasi pada data yang terdapat dalam kolom 'jumlah'. Proses ekstraksi fitur dilakukan pada kolom tersebut untuk menghasilkan sebuah lapisan masukan (input layer), yang dilambangkan dengan X . Setiap entri dalam lapisan masukan tersebut dipasangkan dengan nilai target terkait. Hasil pembentukan fitur ini dirangkum dalam Tabel 3.

Tabel 3. Formasi Fitur

No	X-1	X-2	X-3	X-4	Target
1	54	37	46	70	76
2	39	44	72	76	26
3	43	72	76	26	74

No	X-1	X-2	X-3	X-4	Target
4	69	78	26	74	52
5	78	28	72	52	58
6	28	72	52	60	62
7	74	50	60	64	72
8	52	58	64	70	91
...	...	...	...	...	...
211	37	35	42	62	71

Penelitian ini menetapkan X_1 sebagai jumlah penjualan pada 1 April, 2 April, dan seterusnya hingga X_4 . Dataset pada Tabel 3 berjumlah 211, yang dihasilkan karena nilai target pertama memerlukan empat data masukan sebelumnya. Data penjualan tanggal 5 Juni 2024 menjadi target awal, dengan data tanggal 1-4 Juni 2024 berfungsi sebagai masukan untuk fitur X_1 sampai X_4 . Langkah selanjutnya adalah normalisasi Min-Max. Data awal dibagi menjadi dua subset, yaitu data latih (90%) dan data uji (10%). Pembagian ini dilakukan mendahului proses normalisasi untuk menjamin validitas pengujian dan optimalisasi nilai galat. Nilai ekstrem (minimum dan maksimum) dari masing-masing subset data telah diidentifikasi: data latih (min=20, max=111) dan data uji (min=3, max=34). Matriks normalisasi dihitung berdasarkan nilai-nilai ini menggunakan acuan persamaan (1).

Tabel 4. Normalisasi Data Latih

No	X-1	X-2	X-3	X-4	Target
1	0,339	0,0508	0,2034	0,6102	0,7119
2	0,0847	0,1695	0,6441	0,7119	0,1017
3	0,1525	0,6441	0,7119	0,1017	0,678
4	0,5932	0,7458	0,1356	0,678	0,3051
5	0,7458	0,1017	0,6441	0,3051	0,4068
6	0,1017	0,6441	0,3051	0,4407	0,4746
7	0,678	0,2712	0,4407	0,5085	0,6441
8	0,3051	0,4068	0,5085	0,6102	0,9661
...	...	...	...	...	...
190	0,0508	0,0169	0,1356	0,4746	0,6271

Tabel 5. Normalisasi Data Uji

No	X-1	X-2	X-3	X-4	Target
191	0,3596	0,1685	0,2697	0,5393	0,6067
192	0,2135	0,2809	0,5506	0,6404	0,0674
193	0,236	0,5618	0,6067	0,0674	0,5843
194	0,5506	0,6517	0,0674	0,6067	0,3596
195	0,6292	0,0674	0,5618	0,3371	0,4045
196	0,0899	0,5843	0,3596	0,4494	0,4719
197	0,5843	0,3146	0,427	0,4719	0,5618
198	0,3596	0,427	0,4944	0,5618	0,7978
...	...	...	...	...	...
211	0,2022	0,1798	0,2584	0,4831	0,5843

Hasil normalisasi data yang dipresentasikan dalam Tabel 4 dan Tabel 5, menunjukkan bahwa seluruh data telah diskalakan ke dalam rentang nilai [0, 1]. Rasio pembagian data 90% (latih) dan 10% (uji) diterapkan sesuai kebutuhan. Tahap selanjutnya melibatkan penggunaan data latih dengan bobot awal masukan dan nilai bias awal. Nilai-nilai ini diinisialisasi secara acak dalam rentang 0 hingga 1, dan rinciannya disajikan dalam Tabel 6.

Tabel 6. Bobot awal Dan Nilai Bias

No	W-1	W-2	W-3
1	0,27	0,22	0,73
2	0,86	0,34	0,48
3	0,19	0,75	0,03
4	0,44	0,21	0,81
No	B-1	B-2	B-3
1	0,2	0,2	0,4

Untuk memperoleh nilai keluaran dari lapisan tersembunyi, digunakan fungsi Hint, sesuai dengan formulasi yang dijelaskan dalam Persamaan (2). Hasil komputasi dari penerapan fungsi tersebut dirangkum dalam Tabel 7.

Tabel 7. Hasil Fungsi H_{INT}

No	H_{int1}	H_{int2}	H_{int3}
1	0,7012	1,1301	0,8298
2	0,7601	1,3301	0,8597
3	0,4989	1,1203	0,9402
4	0,9011	1,6011	1,1101
5	0,6612	1,1702	1,1002
6	0,6298	1,1612	0,7398
...	...	...	...
190	0,8998	1,5502	1,1396

Fungsi aktivasi binary sigmoid diterapkan pada nilai keluaran lapisan tersembunyi untuk mendapatkan hasil akhir. Perhitungan ini mengacu pada fungsi $H(x)$ yang diformulasikan dalam Persamaan (3). Hasil dari penerapan fungsi aktivasi tersebut didokumentasikan secara lengkap dalam Tabel 8.

Tabel 8. Hasil Fungsi Aktivasi Binary Sigmoid

No	H_{x1}	H_{x2}	H_{x3}
1	0,6685	0,7559	0,6963
2	0,6814	0,7909	0,7026
3	0,6222	0,754	0,7191
4	0,7112	0,8322	0,7521
5	0,7112	0,8245	0,7583
6	0,6524	0,7616	0,677
...	...	...	...
190	0,7109	0,8249	0,7576

Matriks transpose dari hasil fungsi aktivasi lapisan tersembunyi, yang dinotasikan sebagai H^T dan ditunjukkan pada Tabel 9.

Tabel 9. Hasil Transpose

Simbol	1	2	3	4	...	190
H_{x1}	0,6685	0,6814	0,6222	0,7112	...	0,7109
H_{x2}	0,7559	0,7909	0,754	0,8322	...	0,8249
H_{x3}	0,6963	0,7026	0,7191	0,7521	...	0,7576

Berikut representasi matriks dari hasil komputasi perkalian antara data H_x dan transposenya, yaitu H^T .

$$\begin{bmatrix} 109,103 & 123,011 & 114,983 \\ 122,968 & 138,969 & 129,987 \\ 114,987 & 129,003 & 119,984 \end{bmatrix}$$

Matriks di bawah ini menunjukkan hasil perhitungan nilai invers yang diperoleh dari perkalian antara transpose matriks dan fungsi aktivasi sigmoid biner.

$$\begin{bmatrix} 6,2346 & -4,8609 & -0,7086 \\ -12,687 & 8,8242 & 2,8152 \\ 7,6629 & -4,6140 & -2,3394 \end{bmatrix}$$

Perhitungan hasil kali nilai invers dan nilai transpose menghasilkan Invers Umum Moore-Penrose (H^+).

Tabel 10. Hasil Moore-Penrose Invers

Simbol	1	2	3	4	...	190
H_{x1}	0,0843	0,2101	0,0201	0,3502	...	0,1699
H_{x2}	0,0752	0,2022	0,0399	0,3201	...	0,1589
H_{x3}	0,0112	0,0211	0,0501	0,0029	...	0,0049

Tahap akhir adalah perhitungan nilai bobot keluaran berdasarkan Persamaan (5), dan hasilnya adalah:
0.7498
0.3201
0.6099

Nilai bobot keluaran yang didapatkan pada proses sebelumnya akan dimanfaatkan dalam proses pengujian guna memperoleh nilai prediksi. Proses pengujian tersebut juga memerlukan data uji ternormalisasi, yang hasilnya disajikan pada Tabel 11.

Tabel 11. Hasil Pengujian Proses H_{init}

No	H_{init1}	H_{init2}	H_{init3}
191	1,5998	2,2001	1,5601

No	H _{init1}	H _{init2}	H _{init3}
192	1,6512	1,9987	1,6798
193	1,6198	2,0899	1,6601
194	1,5901	2,0995	1,5703
195	1,6013	2,0102	1,6296
...	...	...	...
211	0,9198	1,3897	0,9597

Nilai fungsi aktivasi dari data pengujian dicari pada langkah berikutnya, dan hasilnya ditunjukkan dalam Tabel 12.

Tabel 12. Hasil Fungsi Aktivasi Proses Pengujian

No	H _{init1}	H _{init2}	H _{init3}
191	0,8298	0,9002	0,7998
192	0,8399	0,9011	0,8402
193	0,8289	0,9102	0,8401
194	0,8297	0,9001	0,8298
195	0,8298	0,8802	0,8403
...	...	...	...
211	0,7201	0,7989	0,7197

Perhitungan nilai prediksi (lapisan keluaran) dilakukan menggunakan sebuah persamaan, yaitu:

$$Y = H \cdot \beta \quad (6)$$

Tabel 13. Hasil Lapisan Output (Prediksi)

No	Hasil
1	0,4222
2	0,6255
3	0,2821
4	0,7645
5	0,3256
6	0,5895
7	0,2344
8	0,3591
9	0,5104
...	...
21	0,6922

Untuk mengembalikan hasil lapisan keluaran ke data asli, dilakukan perhitungan denormalisasi data menggunakan persamaan:

$$v = v'(max - min) + min \quad (7)$$

Pada Tabel 14 ditampilkan hasil dari proses denormalisasi data.

Tabel 14. Hasil Denormalisasi Data

No	Hasil
1	59,0114
2	71,1002
3	49,9254
4	81,0122
5	57,0111
6	70,1801
7	510377
8	56,8798
9	69,0475
...	...
21	76,8791

3.2 Pembahasan Nilai Error

MAPE adalah metode pengukuran yang digunakan untuk membandingkan nilai error dengan hasil prediksi, di mana perhitungannya dilakukan menggunakan persamaan:

$$MAPE = \sum_{t=1}^n \frac{x_t - y_t}{x_t} \times 100\% \quad (8)$$

Tabel 15. Persentase Rata-Rata Kesalahan

No	Error Value
1	6.493%
2	7.929%
3	9.776%
4	13.481%
5	9.983%
6	5.741%
...	...
21	7,751%

Rata-rata nilai kesalahan (error) yang diperoleh untuk seluruh data adalah 8,274%.

3.3 Analisis Hasil Eksperimen Kombinasi Jumlah Fitur, Neuron Tersembunyi, dan Epoch

Jumlah fitur data terbaik dan paling sesuai ditetapkan berdasarkan hasil pengujian, yang bertujuan untuk menghasilkan nilai eror terendah dalam sistem prediksi penjualan kopi. Fitur-fitur tersebut ditentukan dengan memanfaatkan data penjualan dari hari sebelumnya sebagai basis pembentukan setiap fiturnya. Rangkuman nilai rata-rata MAPE (%) untuk setiap variasi fitur dan jumlah neuron tersembunyi ditampilkan dalam Tabel 16.

Tabel 16. Evaluasi Perbandingan Rerata MAPE terhadap Variasi Fitur, Hidden Neuron, dan Epoch pada Model

Jumlah Fitur	Jumlah Neurons Tersembunyi (%)													
	2		3		4		5		6		7		8	
	Error	Ep	Error	Ep	Error	Ep	Error	Ep	Error	Ep	Error	Ep	Error	Ep
1	7,02	3	9,71	4	9,61	4	14,87	4	16,89	5	12,86	8	13,05	9
2	9,71	5	8,97	5	8,02	9	16,99	9	14,03	13	27,99	15	25,96	15
3	9,48	6	7,01	9	10,98	11	14,98	14	27,74	19	14,88	20	22,35	24
4	9,48	15	8,39	12	7,89	15	17,54	20	12,12	25	18,04	29	10,97	31
5	9,97	11	5,99	14	15,02	21	17,52	25	12,99	29	20,99	34	27,62	41
6	10,89	11	6,01	17	8,13	25	13,19	30	17,55	36	15,12	43	20,96	47
7	12,98	13	8,98	20	5,96	2	13,97	34	12,41	41	25,01	50	12,36	54
8	6,99	15	8,61	23	19,01	33	15,98	39	19,61	49	12,52	55	23,04	65

Konfigurasi yang menggabungkan fitur data pada baris ke-6 dan neuron tersembunyi pada kolom ke-3 terbukti paling unggul menurut data Tabel 16. Melalui 18 iterasi epoch, model ini secara signifikan meminimalkan tingkat kesalahan hingga mencapai angka MAPE minimum, yaitu 5,65%.

3.4. Analisis Hasil Eksperimen terhadap Variasi Jumlah Fitur, Neuron Tersembunyi, dan Jumlah Epoch

Tabel 16 menyimpulkan bahwa jumlah fitur data, jumlah neuron tersembunyi, dan jumlah epoch berdampak pada hasil prediksi. Terlihat pula bahwa peningkatan jumlah neuron tersembunyi menyebabkan nilai eror yang semakin besar. Kondisi ini terjadi akibat overfitting, yakni pembentukan pola yang berlebihan pada data yang sederhana, membuatnya sulit diidentifikasi dan menghasilkan peningkatan eror yang signifikan. Hasil pengujian ini menjadi referensi untuk menemukan nilai prediksi terbaik (yang terdekat dengan nilai asli) dan menghasilkan eror MAPE terendah dalam penelitian ini. Penelitian ini selanjutnya menguji data penjualan untuk mengekstrak nilai prediksi optimal melalui konfigurasi parameter terbaik, yakni 6 fitur data, 3 neuron tersembunyi, dan proses pelatihan selama 18 epoch. Hasil uji coba ini ditampilkan pada Tabel 17.

Tabel 17. Komparasi Data Aktual Dan Hasil Prediksi

Data	Nilai Aktual	Nilai Prediksi	MAPE (%)
1	63	61,58	2,25
2	77	59,71	22,45
3	56	51,83	7,45
4	93	89,44	3,83
5	63	61,92	1,71
6	74	69,67	5,85
7	43	41,88	2,66
8	64	59,49	7,05
9	77	71,32	7,38
10	53	50,61	4,51
11	39	37,12	4,82

Data	Nilai Aktual	Nilai Prediksi	MAPE (%)
12	85	77,87	8,39
13	62	60,28	2,77
14	54	50,11	7,21
15	55	60,07	-9,22
16	38	35,86	5,63
17	34	33,64	1,06
18	41	42,52	-3,71
19	63	68,27	-8,37
20	74	78,39	-5,93

Data dalam Tabel 17 menampilkan hasil prediksi yang diperoleh menggunakan 6 fitur terbaik dan 3 neuron tersembunyi terbaik. Rata-rata nilai eror MAPE yang dihasilkan dari kombinasi optimal ini adalah 3,39%.

3.5. Pembahasan

Untuk memvalidasi keandalan dan akurasi model prediksi yang diusulkan, dilakukan analisis komparatif antara hasil eksperimen ELM pada penelitian ini dengan temuan dari beberapa penelitian terdahulu. Perbandingan fokus studi, metode, dan nilai akurasi berbasis MAPE dirangkum dalam Tabel 18.

Tabel 18. Perbandingan Performa Model dengan Penelitian Terdahulu


Peneliti & Referensi	Metode yang Digunakan	Objek / Fokus Penelitian	Nilai Galat
Nariyana dkk. [16]	CatBoost	Volume pembelian kedai kopi retail	15,00%
Setiadi dkk. [17]	ELM vs SVR	Harga saham perbankan di Indonesia	Unggul dalam waktu komputasi
Das & Chakrabarti [18]	ELM	Indeks Harga Grosir (HGI) makanan	Akurasi ~87% (Eror ~13,00%)
Permata & Habibi [19]	ARIMA	Penjualan produk celana jeans	17,05%
Penelitian Ini (Setyadi dkk.)	Optimasi Parameter ELM	Penjualan Kedai Kopi Pait Karanganyar	3,39%

Berdasarkan Tabel 18, konfigurasi optimal ELM yang diajukan dalam penelitian ini (6 fitur masukan, 3 hidden neuron, dan 18 epoch) terbukti menghasilkan performa peramalan yang sangat unggul dengan nilai MAPE mencapai 3,39%. Jika diklasifikasikan berdasarkan rentang nilai akurasi pada Tabel 1, hasil prediksi ini masuk ke dalam kategori Sangat Akurat (nilai MAPE < 10%). Jika dikomparasikan dengan pemodelan linier tradisional seperti model ARIMA (3,1,1) milik Permata dan Habibi [19] yang menghasilkan MAPE 17,05%, pendekatan jaringan saraf tiruan non linier dalam studi ini jauh lebih handal dalam menangani volatilitas data penjualan retail harian. Hal ini dikarenakan data penjualan riil pada Kedai Kopi Pait memiliki fluktuasi acak yang sulit ditangkap oleh fungsi linier sederhana pada ARIMA.

Lebih lanjut, jika disandingkan dengan penerapan model pembelajaran mesin non linier lain pada objek sejenis, seperti model CatBoost oleh Nariyana dkk. [16] yang mencatat MAPE sebesar 15,00%, algoritma ELM dalam riset ini terbukti menghasilkan galat yang jauh lebih minim. Keunggulan ini disebabkan oleh efektivitas prapemrosesan data melalui normalisasi Min-Max yang tepat, dikombinasikan dengan pencarian eksperimental jumlah fitur dan densitas hidden neuron yang optimal, sehingga mampu memetakan pola runtun waktu secara presisi tanpa mengalami fenomena underfitting. Meskipun penelitian ELM terdahulu oleh Setiadi dkk. [17] dan Das dkk. [18] telah mengonfirmasi efisiensi komputasi algoritma ini, keduanya cenderung mengabaikan pencarian parameter internal jaringan secara bertahap atau menerapkannya pada data agregat makro. Studi ini berhasil menjembatani batasan tersebut dengan membuktikan secara empiris bahwa ELM berbiaya komputasi rendah sangat tangguh dan aplikatif untuk skala bisnis retail mikro lokal, asalkan arsitektur jaringannya dikonfigurasi secara ketat guna meminimalkan risiko overfitting.

4. KESIMPULAN

Penerapan metode ELM dalam penelitian ini terbukti efektif untuk memprediksi volume penjualan minuman kopi di Kedai Kopi Pait Karanganyar. Eksperimen ini dilakukan sebanyak delapan kali pengujian menggunakan rasio pembagian data sebesar 90% untuk data latih dan 10% untuk data uji (testing data), serta menerapkan fungsi aktivasi binary sigmoid dalam pemrosesan arsitekturnya. Berdasarkan hasil pengujian awal, algoritma ini mampu menghasilkan nilai galat yang relatif kecil, yaitu sebesar 1,06% saat mengimplementasikan konfigurasi empat jumlah fitur dan tiga jumlah neuron tersembunyi. Sementara itu, melalui serangkaian uji coba eksperimental parameter arsitektur yang lebih komprehensif, konfigurasi optimal yang berhasil diidentifikasi adalah kombinasi 6 fitur masukan terbaik, 3 hidden neuron, dan proses pelatihan (epoch) yang berhenti pada iterasi ke-18. Melalui konfigurasi arsitektur terbaik tersebut, model berhasil memperoleh tingkat galat MAPE rata-rata yang sangat



optimal, yaitu sebesar 3,39%. Secara teoretis dan praktis, penelitian ini memberikan kontribusi signifikan sebagai panduan strategis dalam digitalisasi kontrol dan manajemen stok bagi industri retail kedai kopi skala mikro atau UMKM. Temuan eksperimental ini menegaskan bahwa penataan kombinasi fitur masukan pada input layer dan kapasitas neuron tersembunyi pada algoritma ELM sangat krusial dan efektif untuk menghasilkan akurasi prediksi non linier yang andal tanpa mengorbankan kecepatan komputasi. Penentuan parameter secara terstruktur ini juga berkontribusi secara ilmiah dalam memetakan serta meminimalkan risiko fenomena overfitting pada data runtun waktu berskala lokal. Sebagai penelitian lanjutan, disarankan untuk menguji pengaruh variasi volume data yang lebih besar serta penggunaan variasi fungsi aktivasi lain terhadap tingkat kesalahan metode ELM demi memperoleh hasil peramalan yang lebih adaptif. Selain itu, studi komparatif secara langsung antara metode ELM dan algoritma pembelajaran mesin mutakhir lainnya sangat direkomendasikan untuk penelitian di masa mendatang guna memperluas referensi keandalan model.

5. PERNYATAAN PENULIS

5.1 Kontribusi Penulis

Konseptualisasi: Heribertus Ary Setyadi dan Pudji Widodo;

Metodologi: Heribertus Ary Setyadi dan Supriyanta;

Perangkat Lunak: Pudji Widodo;

Validasi: Pudji Widodo dan Supriyanta;

Analisis Formal: Heribertus Ary Setyadi dan Pudji Widodo;

Investigasi: Heribertus Ary Setyadi dan Supriyanta;

Sumber Daya: Heribertus Ary Setyadi;

Kurasi Data: Supriyanta;

Penulisan Draf Awal: Heribertus Ary Setyadi;

Penulisan, Peninjauan, dan Penyuntingan: Heribertus Ary Setyadi, Pudji Widodo, dan Supriyanta;

Visualisasi: Pudji Widodo dan Supriyanta.

Seluruh penulis telah membaca dan menyetujui versi manuskrip yang telah diterbitkan.

5.2 Ketersediaan Data

Data penjualan harian yang disajikan dan digunakan dalam penelitian ini tersedia secara terbuka untuk keperluan akademis berdasarkan permintaan yang diajukan langsung kepada penulis korespondensi.

5.3 Pendanaan

Proses penelitian, analisis eksperimental, hingga penulisan dan penerbitan manuskrip ilmiah ini didanai secara mandiri (swadana) oleh para penulis tanpa adanya bantuan dana atau hibah dari lembaga eksternal manapun.

5.4 Pernyataan Dewan Peninjau Institusional

Tidak Berlaku (Not applicable). Penelitian ini tidak melibatkan subjek manusia, hewan coba, ataupun uji klinis medis yang memerlukan persetujuan dari komite etik atau dewan peninjau institusional.

5.5 Pernyataan Persetujuan Berdasarkan Informasi

Tidak Berlaku (Not applicable). Penelitian ini menggunakan data sekunder berupa catatan operasional volume penjualan kedai kopi retail yang bersifat non personal, sehingga tidak memerlukan lembar persetujuan tindakan medis atau persetujuan personal berbasis informasi.

5.6 Pernyataan Konflik Kepentingan

Para penulis menyatakan bahwa mereka tidak memiliki kepentingan keuangan yang bersaing atau hubungan pribadi yang diketahui yang dapat dianggap memengaruhi pekerjaan yang dilaporkan dalam artikel ini.


5.7 Penggunaan AI Generatif dan Teknologi Berbantuan AI dalam Proses Penulisan

Para penulis menggunakan AI Generatif untuk meningkatkan kejelasan penulisan dalam artikel ini. Para penulis telah meninjau dan menyunting konten yang dihasilkan dengan bantuan AI serta bertanggung jawab penuh atas versi akhir publikasi.

REFERENCES

- [1] F. Orduna-Cabrera et al., "Short-Term Forecasting Arabica Coffee Cherry Yields by Seq2Seq over LSTM for Smallholder Farmers," *Sustain.*, vol. 17, no. 9, pp. 1–14, 2025, doi: 10.3390/su17093888.
- [2] L. Setiyani and W. H. Utomo, "Arabica Coffee Price Prediction Using the Long Short Term Memory Network (LSTM) Algorithm," *Sci. J. Informatics*, vol. 10, no. 3, pp. 287–296, 2023, doi: 10.15294/sji.v10i3.44162.
- [3] S. Meepprom and A. Kokkhangplu, "Customer experience and satisfaction in coffee consumption: an experiential marketing perspective," *Cogent Bus. Manag.*, vol. 12, no. 1, p., 2025, doi: 10.1080/23311975.2025.2450296.





- [4] W. Wahyuningsih and P. T. Prasetyaningrum, “Enhancing Sales Determination for Coffee Shop Packages through Associated Data Mining: Leveraging the FP-Growth Algorithm,” *J. Inf. Syst. Informatics*, vol. 5, no. 2, pp. 758–770, 2023, doi: 10.51519/journalisi.v5i2.500.
- [5] R. S. Hendiarto, R. F. Laksana, and F. Alhafizh, “Influence of Store Atmosphere and Price on Costumer Loyalty (Study at Diantara Kopi Coffee Shop in Bandung),” *Owner*, vol. 8, no. 3, pp. 2834–2842, 2024, doi: 10.33395/owner.v8i3.2088.
- [6] Y. L. Chen and Y. C. Chen, “Impact of Brand and Testing Method on Coffee Taste Perception between Genders: A Comparative Study of Two Leading Coffee Brands in Taiwan,” *SAGE Open*, vol. 15, no. 1, pp. 1–12, 2025, doi: 10.1177/21582440251316087.
- [7] S. M. M. MangusStephanie M, “Personal selling and sales management abstracts,” *J. Pers. Sell. Sales Manag.*, vol. 44, no. 4, pp. 343–354, 2024, doi: 10.1080/08853134.2024.2415453.
- [8] Y. Chen, “Research on Machine Learning-based Prediction of Coffee Futures Prices,” *Highlights Sci. Eng. Technol.*, vol. 92, pp. 199–209, 2024, doi: 10.54097/8c9t9n30.
- [9] M. Miranda and S. Sriani, “Implementation of K-Means Clustering in Grouping Sales Data at Zura Mart,” *J. Appl. Informatics Comput.*, vol. 9, no. 2, pp. 547–555, 2025, doi: 10.30871/jaic.v9i2.9160.
- [10] V. R. Danestiara, M. Marwondo, and N. N. Azkiya, “Prediction of Inhibitor Binding Affinity and Molecular Interactions in Mpro Dengue Using Machine Learning,” *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 10, no. 3, pp. 461–468, 2025, doi: 10.33480/jitk.v10i3.5994.
- [11] S. Febriani, V. Wati, Y. Wijayanti, and I. Siswanto, “Twitter Sentiment Analysis on Digital Payment in Indonesia Using Artificial Neural Network,” *J. Appl. Informatics Comput.*, vol. 9, no. 2, pp. 526–533, 2025, doi: 10.30871/jaic.v9i2.8988.
- [12] M. Vinoth Kumar, G. Kiran Kumar, A. M. Ali, S. K. Rajesh Kanna, and K. Muthu Lakshmi, “Analysis of Extreme Learning Machine Based on Multiple Hidden Layers,” *Int. J. Intell. Syst. Appl. Eng.*, vol. 12, no. 95, pp. 96–103, 2024, [Online]. Available: <https://www.ijisae.org/index.php/IJISAE/article/view/4208>
- [13] F. Mercaldo, L. Brunese, F. Martinelli, A. Santone, and M. Cesarelli, “Experimenting with Extreme Learning Machine for Biomedical Image Classification,” *Appl. Sci.*, vol. 13, no. 14, pp. 1–20, 2023, doi: 10.3390/app13148558.
- [14] A. P. Ariyanti, M. I. Mazdadi, A.- Farmadi, M. Muliadi, and R. Herteno, “Application of Extreme Learning Machine Method With Particle Swarm Optimization to Classify of Heart Disease,” *IJCCS (Indonesian J. Comput. Cybern. Syst.*, vol. 17, no. 3, p. 281, 2023, doi: 10.22146/ijccs.86291.
- [15] R. Fredyan, M. R. N. Majid, and G. P. Kusuma, “Spatiotemporal Analysis for Rainfall Prediction Using Extreme Learning Machine Cluster,” *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 13, no. 6, pp. 2240–2248, 2023, doi: 10.18517/ijaseit.13.6.18214.
- [16] C. D. Nariyana, M. Idhom, and Trimono, “Prediction of Purchase Volume Coffee Shops in Surabaya Using Catboost with Leave-One-Out Cross Validation,” *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 11, no. 1, pp. 124–138, 2025, doi: 10.26555/jiteki.v11i1.30610.
- [17] W. K. Setiadi, V. R. Prasetyo, and F. D. Kartikasari, “Comparison of Extreme Learning Machine Methods and Support Vector Regression for Predicting Bank Share Prices in Indonesia,” *Teknika*, vol. 13, no. 2, pp. 219–225, 2024, doi: 10.34148/teknika.v13i2.856.
- [18] D. Das and S. Chakrabarti, “An Extreme Learning Machine Approach for Forecasting the Wholesale Price Index of Food Products in India,” *Pertanika J. Sci. Technol.*, vol. 31, no. 6, pp. 3179–3198, 2023, doi: 10.47836/pjst.31.6.30.
- [19] J. M. A. C. Permata and M. Habibi, “Autoregressive Integrated Moving Average (ARIMA) Models For Forecasting Sales Of Jeans Products,” *J. Inform. dan Teknol. Inf.*, vol. 20, no. 1, pp. 31–40, 2023, doi: 10.31515/telematika.v20i1.7868.
- [20] M. Khairunisa, D. M. S. A. Putri, and I. G. N. L. Wijayakusuma, “Comparison of Machine Learning Methods for Menstrual Cycle Analysis and Prediction,” *J. Appl. Informatics Comput.*, vol. 9, no. 2, pp. 348–353, 2025, doi: 10.30871/jaic.v9i2.9076.
- [21] S. Aisyah, N. Ulinnuha, and A. Hamid, “Penerapan Extreme Learning Machine Dalam Meramalkan Harga Minyak Sawit Mentah,” *KUBIK J. Publ. Ilm. Mat.*, vol. 7, no. 2, pp. 97–105, 2023, doi: 10.15575/kubik.v7i2.20460.
- [22] M. Warohma, E. Budianita, F. Syafria, and I. Afrianty, “Prediksi Jumlah Perceraian Menggunakan Metode Extreme Learning Machine (ELM),” *J. Inf. Syst. Res.*, vol. 4, no. 4, pp. 1448–1454, 2023, doi: 10.47065/josh.v4i4.3581.
- [23] D. Yustisio, E. Siswanah, and M. Tafrikan, “Extreme Learning Machine and Multilayer Perceptron Methods for Predicting COVID-19,” *Sink. J. dan Penelit. Tek. Inform.*, vol. 8, no. 4, pp. 2298–2309, 2024, doi: <https://doi.org/10.33395/sinkron.v8i4.14029>.
- [24] C. Wiedyaningsih, E. Yuniarti, and A. Fadilla, “FORECASTING CARDIOVASCULAR DRUG DEMAND USING TRIPLE EXPONENTIAL SMOOTHING ADDITIVE,” *Indones. J. Glob. Heal. Res.*, vol. 7, no. 1, pp. 29–34, 2025, doi: 10.37287/ijghr.v2i4.250.