



Volume 01, Nomor 01, Juli 2026, hlm 33-43

JIIE

Journal of Integrated Industrial Engineering

p ISSN | e ISSN

http://



OPTIMASI ARSITEKTUR ARTIFICIAL NEURAL NETWORK (ANN) MENGGUNAKAN GENETIC ALGORITHM (GA) DALAM PERAMALAN PERMINTAAN PADA UMKM ROTI MADHANI

Radithya Akbar¹, Deva Adhitya Pradana², Mikhael Fernando H S³, Michael Mangihut Tua S⁴, Dian Fajarika⁵

^{1,2,3,4,5}Program Studi Teknik Industri, Fakultas Teknologi Industri, Institut Teknologi Sumatera, Indonesia

INFORMASI ARTIKEL

ABSTRAK

Article History:

Submission: 10-07-2026

Revised: 25-07-2026

Accepted: 30-07-2026

Kata Kunci:

Peramalan Permintaan,
Jaringan Saraf Tiruan,
Algoritma Genetika,
Optimasi Arsitektur,
UMKM.

Keywords:

Demand Forecasting,
Artificial Neural
Network, Genetic
Algorithm, Architecture
Optimization, SME.

Korespondensi:

Author

radithya.123190032
@student.itera.ac.id

Fluktuasi permintaan produk pada UMKM ROTI MADHANI menyulitkan perencanaan produksi dan pengelolaan persediaan, sementara metode peramalan statistik konvensional kurang mampu menangkap pola permintaan yang non-linier dan kompleks. Penelitian ini bertujuan mengembangkan model prediksi permintaan finished goods menggunakan Artificial Neural Network (ANN) yang arsitekturnya dioptimasi dengan Genetic Algorithm (GA), agar diperoleh konfigurasi jaringan optimal tanpa trial-and-error manual. Data yang digunakan adalah 50 data historis bulanan (Januari 2022–Februari 2026) dengan lima variabel input, yaitu harga jual, indeks marketing, indeks hari besar, stok tersedia, dan kunjungan media sosial, serta permintaan produk sebagai variabel output. GA digunakan untuk mengoptimasi jumlah hidden layer, jumlah neuron, learning rate, dan batch size dengan ukuran populasi 8 kromosom selama 15 generasi, sedangkan ANN dilatih menggunakan algoritma backpropagation dengan optimizer Adam. Hasil optimasi menghasilkan arsitektur ANN dengan 3 hidden layer (56, 42, dan 26 neuron), learning rate 0,01, dan batch size 16. Evaluasi pada data pengujian menunjukkan model memperoleh MAE sebesar 94,4854, RMSE sebesar 102,5628, MAPE sebesar 21,10%, dan R^2 sebesar 98,89%. Hasil ini menunjukkan bahwa model ANN-GA mampu memprediksi permintaan finished goods dengan akurasi yang baik dan dapat digunakan sebagai alat bantu pengambilan keputusan dalam perencanaan produksi dan pengendalian persediaan pada UMKM Roti Madhani.

ABSTRACT

Demand fluctuation for finished goods at UMKM Roti Madhani made production planning and inventory management difficult, while conventional statistical forecasting methods were less able to capture non-linear and complex demand patterns. This study aimed to develop a finished-goods demand prediction model using an Artificial Neural Network (ANN) whose architecture was optimized with a Genetic Algorithm (GA), so that an optimal network configuration could be obtained without manual trial-and-error. The dataset consisted of 50 monthly historical records (January 2022–February



JIIE: Journal Of Integrated Industrial Engineering (JIIE) is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

2026) with five input variables — selling price, marketing index, holiday index, available stock, and social media visits — and product demand as the output variable. GA was used to optimize the number of hidden layers, number of neurons, learning rate, and batch size using a population of 8 chromosomes over 15 generations, while the ANN was trained with the backpropagation algorithm and the Adam optimizer. The optimization produced an ANN architecture with 3 hidden layers (56, 42, and 26 neurons), a learning rate of 0.01, and a batch size of 16. Evaluation on the testing data showed the model achieved an MAE of 94.4854, an RMSE of 102.5628, a MAPE of 21.10%, and an R^2 of 98.89%. These results indicate that the ANN-GA model can predict finished-goods demand with good accuracy and can be used as a decision-support tool for production planning and inventory control at UMKM Roti Madhani.

1. PENDAHULUAN

Kemampuan perusahaan dalam mengelola persediaan menjadi salah satu faktor penting. Manajemen persediaan bertujuan untuk memastikan bahwa tingkat produksi serta penjualan terdapat keselarasan, sehingga dapat memenuhi kebutuhan tanpa menimbulkan biaya atas overstock maupun overproduction [1]. Salah satu aspek utama dalam manajemen persediaan adalah prediksi permintaan (demand forecasting), yaitu proses memprediksi jumlah permintaan produk pada periode mendatang berdasarkan data historis maupun faktor-faktor yang memengaruhinya.

Salah satu tantangan UMKM ialah tingginya fluktuasi permintaan produk yang dipengaruhi oleh perubahan tren pasar, promosi, kondisi ekonomi, dan perilaku konsumen. Ketidakpastian permintaan tersebut dapat menyebabkan terjadinya overstock maupun stockout [2]. Overstock mengakibatkan penumpukan persediaan yang meningkatkan biaya penyimpanan dan mengikat modal kerja perusahaan, sedangkan stockout menyebabkan hilangnya peluang penjualan serta menurunkan kepuasan pelanggan.

Banyak perusahaan masih menggunakan metode peramalan konvensional berbasis statistik, seperti Moving Average, Exponential Smoothing, maupun Regresi Linier. Metode ini cukup efektif apabila data memiliki pola sederhana dan hubungan antarvariabel bersifat linier [2]. Namun permintaan UMKM sering menunjukkan pola yang lebih kompleks, non-linier, dan musiman, sehingga metode statistik konvensional sering kali tidak mampu menangkap pola data secara optimal dan akurasi prediksinya menjadi kurang memadai untuk mendukung pengambilan keputusan operasional [2].

Perkembangan kecerdasan buatan (Artificial Intelligence) memberikan alternatif yang lebih adaptif dalam mengatasi permasalahan peramalan. Artificial Neural Network (ANN) merupakan model komputasi yang terinspirasi dari cara kerja jaringan saraf manusia dan mampu mempelajari pola hubungan yang kompleks dari data [3]. Berbeda dengan metode statistik konvensional, ANN mampu menangani hubungan non-linier antarvariabel serta mengakomodasi berbagai faktor yang memengaruhi permintaan secara simultan melalui pendekatan multi-variabel, sehingga berpotensi menghasilkan prediksi yang lebih akurat.

Meskipun memiliki kemampuan prediksi yang mumpuni, penerapan ANN masih menghadapi tantangan dalam proses pembentukan model karena akurasi sangat dipengaruhi oleh konfigurasi arsitektur jaringan, seperti jumlah hidden layer, jumlah neuron pada setiap layer, learning rate, serta parameter pelatihan lainnya. Penentuan parameter tersebut umumnya dilakukan melalui pendekatan trial-and-error yang memerlukan waktu, sumber daya komputasi,

dan pengalaman pengguna, sehingga berisiko menghasilkan akurasi yang kurang optimal atau mengalami overfitting maupun underfitting [4].

Diperlukan metode optimasi yang mampu mencari konfigurasi arsitektur ANN secara otomatis dan sistematis. Genetic Algorithm (GA) merupakan metode optimasi berbasis evolusi yang meniru mekanisme seleksi alam dalam menemukan solusi terbaik dari suatu permasalahan [5]. GA dapat digunakan untuk menentukan kombinasi parameter jaringan yang optimal, seperti jumlah hidden layer, jumlah neuron, dan learning rate, sehingga diperoleh model yang lebih efektif sekaligus mengurangi subjektivitas dan mempercepat pencarian konfigurasi terbaik dibandingkan metode trial-and-error [4]. Berdasarkan uraian tersebut, penelitian ini mengintegrasikan ANN dan GA untuk mengoptimasi arsitektur jaringan dalam meramalkan permintaan finished goods pada UMKM Roti Madhani.

Rumusan Masalah

Rumusan masalah pada penelitian ini meliputi: (1) bagaimana mengatasi fluktuasi permintaan finished goods pada UMKM Roti Madhani untuk mendukung perencanaan produksi dan pengelolaan persediaan; (2) bagaimana menentukan arsitektur ANN yang optimal menggunakan Algoritma Genetika tanpa trial-and-error manual; serta (3) bagaimana kinerja model ANN multi-variabel yang dioptimasi dengan Algoritma Genetika dalam memprediksi permintaan finished goods pada UMKM Roti Madhani.

Tujuan Penelitian

Tujuan penelitian ini adalah menganalisis fluktuasi permintaan finished goods pada UMKM Roti Madhani, menentukan arsitektur ANN yang optimal menggunakan Algoritma Genetika, serta mengembangkan dan mengevaluasi kinerja model ANN multi-variabel yang dioptimasi dengan Algoritma Genetika dalam memprediksi permintaan finished goods.

Batasan Penelitian

Penelitian ini dilakukan pada UMKM Roti Madhani dengan fokus pada prediksi permintaan finished goods berdasarkan data historis yang tersedia. Model prediksi yang digunakan adalah ANN berbasis pendekatan multi-variabel dengan optimasi arsitektur jaringan menggunakan GA, sedangkan kinerja model dievaluasi menggunakan indikator MAE, RMSE, MAPE, dan koefisien determinasi (R^2).

2. LANDASAN TEORI

Manajemen Persediaan dan Peramalan Permintaan

Manajemen persediaan adalah landasan utama dalam manajemen rantai pasok yang berperan penting terhadap kinerja keuangan perusahaan. Secara umum, manajemen persediaan melibatkan pengelolaan stok barang untuk menyeimbangkan pasokan dan permintaan guna menghindari risiko operasional seperti stockout, overstocking, maupun backorder. Tujuan intinya adalah memaksimalkan laba dengan meningkatkan layanan pelanggan dan meminimalkan biaya keseluruhan [6]. Peramalan permintaan adalah proses mengestimasi kebutuhan konsumen di masa depan untuk memastikan ketersediaan produk yang tepat pada waktu yang tepat, dan dianggap sebagai pengembangan strategis yang krusial dalam sistem informasi persediaan [7].

Artificial Neural Network (ANN)

ANN adalah metode pembelajaran mesin yang dirancang untuk menyimulasikan cara kerja otak manusia melalui lapisan-lapisan node yang saling terhubung [8], terdiri atas input layer, hidden layer, dan output layer [9]. Dibandingkan metode statistik tradisional, ANN memiliki keunggulan dalam menangani pola non-linear yang kompleks [8], menghasilkan akurasi prediksi yang lebih tinggi [8], beradaptasi terhadap volatilitas tinggi [3], toleran terhadap data yang tidak pasti [9], serta mampu melakukan analisis multidimensional dengan mengintegrasikan berbagai variabel input sekaligus [11]. Kinerja ANN sangat dipengaruhi oleh pemilihan hyperparameter yang tepat;

kesalahan dalam menentukan jumlah hidden layer dan neuron dapat menyebabkan overfitting maupun underfitting [12], sehingga ANN sering dikombinasikan dengan Genetic Algorithm untuk memperoleh performa prediksi yang lebih baik.

Genetic Algorithm (GA)

GA adalah teknik pencarian dan optimasi yang mengemulasi proses evolusi biologis berdasarkan prinsip “survival of the fittest” [9]. Proses evolusi dalam GA digerakkan oleh tiga operator utama [13]: (1) seleksi, memilih individu dengan fitness tinggi sebagai induk generasi berikutnya; (2) crossover, menggabungkan materi genetik dari dua induk untuk menghasilkan keturunan baru; dan (3) mutasi, mengubah sebagian kecil gen secara acak untuk menjaga keragaman populasi dan mencegah konvergensi prematur pada local optimum. GA sering diintegrasikan dengan ANN membentuk model hibrida GA-ANN, yang berperan mengoptimalkan bobot awal jaringan [14], mencegah model terjebak dalam local minima, serta mengoptimalkan arsitektur jaringan sehingga tidak lagi bergantung pada trial-and-error [11].

Metrik Evaluasi Kinerja Model

Untuk mengevaluasi kualitas peramalan, digunakan metrik MSE (Mean Squared Error), RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), dan MAPE (Mean Absolute Percentage Error) [15]. MSE mengukur rata-rata selisih kuadrat antara nilai prediksi dan aktual, dan sangat sensitif terhadap outlier:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

RMSE merupakan akar kuadrat dari MSE sehingga hasilnya berada pada satuan yang sama dengan data asli:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2)$$

MAE mengukur rata-rata deviasi absolut antara nilai aktual dan nilai prediksi tanpa memberi penalti berlebih terhadap deviasi besar:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

MAPE menyatakan tingkat kesalahan prediksi dalam bentuk persentase sehingga mudah diinterpretasikan dan dibandingkan antar dataset:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

Nilai MAPE di bawah 10% menunjukkan akurasi model sangat baik, 10–20% baik, 20–50% cukup, dan di atas 50% menunjukkan akurasi rendah.

3. METODE PENELITIAN

Objek dan Alur Penelitian

Objek penelitian ini adalah UMKM Roti Madhani, pelaku usaha di bidang industri makanan dengan produk utama roti manis yang kerap menghadapi fluktuasi permintaan pasar yang sulit diprediksi. Penelitian menggunakan data historis operasional UMKM periode Januari 2022 hingga Februari 2026, sebanyak 50 data bulanan, yang dianggap cukup representatif untuk mendukung pembangunan model prediksi permintaan.

Penelitian ini berfokus pada prediksi permintaan produk jadi (finished goods) berupa roti manis dengan mengintegrasikan Artificial Neural Network (ANN) dan Genetic Algorithm (GA), di mana ANN berperan mempelajari pola hubungan antar variabel yang memengaruhi permintaan,

sedangkan GA digunakan untuk mengoptimalkan parameter model agar diperoleh akurasi prediksi yang lebih baik. Alur penelitian dimulai dari penetapan objek dan observasi langsung, pengumpulan data mentah dari catatan internal UMKM, pra-pemrosesan data (pembersihan data, seleksi variabel, dan normalisasi), pembagian data training dan testing (80:20), pembangunan model ANN-GA melalui optimasi hyperparameter oleh GA selama 15 generasi, pelatihan model final menggunakan backpropagation, hingga evaluasi kinerja model menggunakan metrik statistik formal yang diakhiri dengan interpretasi hasil sebagai rekomendasi strategis bagi manajemen UMKM Roti Madhani.

Pengolahan Data

Data yang dikumpulkan bersifat primer dan terstruktur dalam bentuk deret waktu bulanan selama 50 bulan (Januari 2022–Februari 2026), terdiri dari lima variabel independen (harga jual produk, indeks aktivitas marketing, indeks hari besar keagamaan/nasional, volume stok yang tersedia, dan jumlah kunjungan media sosial resmi perusahaan) dan satu variabel dependen, yaitu volume permintaan (Permintaan_Demand).

Pemeriksaan data hilang dilakukan menggunakan fungsi `isnull().sum().sum()` dari library Pandas, dan apabila ditemukan maka data dihapus menggunakan `dropna()`. Pemeriksaan data duplikat dilakukan menggunakan fungsi `duplicated().sum()`, dan data duplikat dihapus menggunakan `drop_duplicates()` agar tidak memengaruhi hasil pembelajaran model. Variabel input yang digunakan meliputi Harga_Jual, Indeks_Marketing, Indeks_Hari_Besar, Stok_Tersedia, dan Kunjungan_Medsos, sedangkan variabel output yang menjadi target prediksi adalah Permintaan_Demand.

Normalisasi data dilakukan menggunakan metode Min-Max Scaling melalui fungsi `MinMaxScaler()` dari library Scikit-Learn, yang mengubah seluruh nilai data ke rentang 0 hingga 1 dengan tetap mempertahankan pola distribusi data asli. Proses normalisasi dilakukan secara terpisah untuk variabel input (X) dan variabel output (y). Secara matematis, normalisasi Min-Max Scaling dinyatakan sebagai berikut:

$$[X_{\{norm\}} = \frac{X - X_{\{min\}}}{X_{\{max\}} - X_{\{min\}}} \quad (5)$$

dengan X_{norm} adalah nilai hasil normalisasi, X adalah nilai data asli, X_{min} adalah nilai minimum, dan X_{max} adalah nilai maksimum pada variabel tersebut. Selanjutnya data dibagi menjadi data pelatihan (80%) dan data pengujian (20%) menggunakan fungsi `train_test_split()` dengan parameter `shuffle=False` karena data bersifat deret waktu.

Pengembangan Model ANN-GA

Jumlah hidden layer dan neuron pada setiap layer ditentukan melalui optimasi GA, dengan kemungkinan satu hingga tiga hidden layer. Fungsi aktivasi ReLU digunakan pada hidden layer, sedangkan fungsi aktivasi linear digunakan pada output layer karena penelitian ini merupakan permasalahan regresi. Arsitektur ANN diimplementasikan menggunakan library TensorFlow dan Keras dengan model Sequential, dilatih menggunakan optimizer Adam (Adaptive Moment Estimation) dengan fungsi kerugian Mean Squared Error (MSE) agar proses konvergensi lebih cepat dan stabil.

Dalam GA, setiap solusi direpresentasikan sebagai kromosom yang terdiri atas beberapa gen, dengan setiap gen mewakili satu parameter ANN yang dioptimasi. Struktur kromosom yang digunakan ditampilkan pada Tabel 1.

Tabel 1. Struktur Kromosom Genetic Algorithm

Gen	Parameter yang Dioptimasi
Gen 1	Jumlah Hidden Layer

Gen	Parameter yang Dioptimasi
Gen 2	Jumlah Neuron Hidden Layer 1
Gen 3	Jumlah Neuron Hidden Layer 2
Gen 4	Jumlah Neuron Hidden Layer 3
Gen 5	Learning Rate
Gen 6	Batch Size

Kinerja setiap kromosom dievaluasi menggunakan fungsi fitness yang dihitung berdasarkan nilai RMSE hasil prediksi model. Karena GA bekerja dengan prinsip memaksimalkan nilai fitness, maka RMSE dikonversi menjadi fitness menggunakan persamaan berikut:

$$[Fitness = \frac{1}{RMSE + 10^{-6}}](6)$$

Semakin kecil nilai RMSE yang dihasilkan model, semakin besar nilai fitness yang diperoleh, sehingga kromosom dengan kesalahan prediksi lebih rendah memiliki peluang lebih besar untuk dipilih pada generasi berikutnya. Proses seleksi, crossover, mutasi, dan evaluasi fitness dilakukan berulang menggunakan library PyGAD dengan ukuran populasi 8 kromosom selama 15 generasi. Kromosom dengan nilai fitness tertinggi pada akhir proses evolusi dipilih sebagai solusi optimal menggunakan fungsi `best_solution()`, dan parameter terbaik yang diperoleh selanjutnya digunakan untuk membangun model ANN final.

Implementasi model dilakukan menggunakan bahasa pemrograman Python dengan library Pandas untuk pengelolaan dataset, NumPy untuk operasi numerik, Matplotlib untuk visualisasi, Scikit-Learn untuk pra-pemrosesan dan evaluasi model, TensorFlow dan Keras untuk pembangunan ANN, serta PyGAD untuk optimasi GA. Proses pelatihan model final dilakukan melalui fungsi `buat_dan_latih_ann()` yang membangun arsitektur jaringan berdasarkan parameter hasil optimasi GA, dikompilasi menggunakan optimizer Adam dan fungsi loss MSE, kemudian dilatih menggunakan fungsi `model.fit()` selama 100 epoch. Model yang telah dilatih kemudian digunakan untuk menghasilkan prediksi permintaan finished goods dan dievaluasi tingkat akurasi.

Evaluasi Model

Perhitungan metrik evaluasi dilakukan menggunakan library Scikit-Learn setelah model menghasilkan prediksi pada data testing melalui fungsi `model.predict()`. Hasil prediksi yang masih berada dalam skala normalisasi dikembalikan ke skala asli menggunakan fungsi `inverse_transform()`, kemudian nilai prediksi dan nilai aktual dibandingkan untuk memperoleh nilai MAE, RMSE, MAPE, dan R^2 . Semakin kecil nilai MAE, RMSE, dan MAPE, serta semakin besar nilai R^2 yang mendekati 1, menunjukkan bahwa model semakin mampu menjelaskan hubungan antara variabel input dan output secara akurat.

Visualisasi hasil dilakukan pada tiga aspek, yaitu kurva loss pelatihan model (untuk memantau kemungkinan overfitting), kurva fitness selama proses optimasi GA (untuk melihat peningkatan kualitas solusi antargenerasi), serta kurva perbandingan nilai aktual dan hasil prediksi pada data testing untuk mengevaluasi kemampuan model mengikuti pola permintaan aktual.

4. HASIL DAN PEMBAHASAN

Deskripsi Data Penelitian

Penelitian ini menggunakan data historis permintaan finished goods UMKM Roti Madhani sebanyak 50 data. Sebelum dilakukan pemodelan ANN dan optimasi GA, data terlebih dahulu dianalisis secara deskriptif untuk mengetahui karakteristik dan distribusi masing-masing variabel, sebagaimana disajikan pada Tabel 2.

Tabel 2. Statistik Deskriptif Data Penelitian

Variabel	Min	Max	Mean	Std Dev
Harga_Jual	6500	7500	6964	363,52
Indeks_Marketing	0	1	0,38	0,49
Indeks_Hari_Besar	0	3	0,54	1,01
Stok_Tersedia	512	5704	1767,12	1565,41
Kunjungan_Medsos	892	9521	3112,40	2610,46
Permintaan_Demand	333	5945	1337,04	1754,60

Seluruh variabel penelitian menunjukkan variasi data yang cukup beragam. Fluktuasi yang tinggi pada variabel permintaan produk mengindikasikan adanya ketidakpastian permintaan, sehingga diperlukan model prediksi untuk membantu perencanaan produksi dan pengendalian persediaan secara lebih efektif.

Pra-Pemrosesan Data

Hasil pemeriksaan missing value dan data duplikat disajikan pada Tabel 3.

Tabel 3. Hasil Pemeriksaan Kualitas Data

Pemeriksaan	Hasil
Missing Value	0
Data Duplikat	0

Seluruh variabel penelitian memiliki jumlah missing value dan data duplikat sebesar nol, yang menunjukkan bahwa dataset telah lengkap sehingga tidak diperlukan proses imputasi atau penghapusan data. Selanjutnya, data dibagi menjadi data training dan testing sebagaimana disajikan pada Tabel 4.

Tabel 4. Pembagian Data Training dan Testing

Jenis Data	Jumlah
Training	40 Data (80%)
Testing	10 Data (20%)
Total	50 Data

Proporsi pembagian 80:20 dipilih karena mampu memberikan jumlah data yang cukup bagi model untuk mempelajari pola historis sekaligus menyediakan data pengujian yang memadai untuk mengevaluasi kinerja model secara efisien.

Optimasi Arsitektur ANN dengan Genetic Algorithm


Pemilihan parameter GA bertujuan memperoleh keseimbangan antara kualitas solusi, kecepatan komputasi, dan kemampuan algoritma dalam mengeksplorasi ruang pencarian, sebagaimana disajikan pada Tabel 5.

Tabel 5. Parameter Genetic Algorithm

Parameter	Nilai
Population Size	8
Jumlah Generasi	15
Parent Mating	3
Mutation Rate	20%

Selection Type	Steady State Selection
Crossover Type	Single Point

Population size sebesar 8 menunjukkan jumlah individu pada setiap generasi, sedangkan jumlah generasi sebanyak 15 menjadi batas iterasi proses evolusi. Parent mating sebesar 3 menentukan jumlah induk yang menghasilkan keturunan, sementara mutation rate 20% diterapkan untuk menjaga keberagaman solusi. Proses seleksi menggunakan steady state selection dan persilangan menggunakan single point crossover.



Gambar 1. Grafik Fitness Genetic Algorithm

Nilai fitness meningkat dari sekitar 41 pada generasi awal menjadi 50 dan bertahan hingga generasi ke-3. Pada generasi ke-5 terjadi peningkatan signifikan hingga mencapai sekitar 151, kemudian nilainya stabil sampai generasi ke-15. Hal ini menunjukkan bahwa GA telah menemukan solusi optimal pada generasi ke-5 dan mencapai kondisi konvergen.


Konfigurasi optimal hasil optimasi GA digunakan untuk membangun model prediksi, sebagaimana disajikan pada Tabel 6.

Tabel 6. Hasil Optimasi Arsitektur ANN

Parameter	Nilai Optimal
Jumlah Hidden Layer	3 layer
Neuron Hidden Layer 1	56 neuron
Neuron Hidden Layer 2	42 neuron
Neuron Hidden Layer 3	26 neuron
Learning Rate	0,01
Batch Size	16
Optimizer	Adam
Aktivasi Hidden Layer	ReLU
Aktivasi Output Layer	Linear


Konfigurasi terbaik terdiri dari 3 hidden layer dengan masing-masing 56, 42, dan 26 neuron, learning rate 0,01, batch size 16, dan optimizer Adam. Fungsi aktivasi ReLU digunakan pada hidden layer, sedangkan output layer menggunakan fungsi aktivasi linear. Kombinasi parameter ini dipilih karena menghasilkan nilai fitness tertinggi selama proses optimasi.

Pelatihan Model dan Hasil Prediksi



Gambar 2. Training Loss dan Validation Loss

Nilai training loss dan validation loss cenderung rendah dan mengikuti pola yang serupa selama proses pelatihan. Meskipun terjadi sedikit peningkatan loss pada beberapa epoch akhir, kedua kurva tetap bergerak konsisten sehingga model ANN-GA menunjukkan kemampuan belajar dan generalisasi yang baik.



Gambar 3. Kurva Hasil Prediksi ANN-GA

Kurva hasil prediksi ANN-GA mengikuti pola data aktual dengan cukup baik. Kedekatan kedua kurva menunjukkan bahwa model mampu merepresentasikan pola permintaan produk dan menghasilkan prediksi yang akurat dengan tingkat kesalahan yang relatif rendah.

Evaluasi Kinerja Model

Kinerja model ANN-GA dievaluasi menggunakan metrik MAE, RMSE, MAPE, dan koefisien determinasi (R^2), sebagaimana disajikan pada Tabel 7.

Tabel 7. Hasil Evaluasi Kinerja Model ANN-GA

Metrik Evaluasi	Nilai
MAE (Mean Absolute Error)	94,4854
RMSE (Root Mean Squared Error)	102,5628
MAPE (Mean Absolute Percentage Error)	21,10%
R^2 (Coefficient of Determination)	98,89%

Model ANN-GA memperoleh nilai MAE dan RMSE yang relatif rendah serta nilai R^2 sebesar 98,89%. Hasil tersebut menunjukkan bahwa model mampu menghasilkan prediksi yang mendekati data aktual dan memiliki kemampuan yang sangat baik dalam menjelaskan variasi

permintaan produk, meskipun nilai MAPE sebesar 21,10% menunjukkan tingkat akurasi berada pada kategori baik, bukan sangat baik, yang kemungkinan dipengaruhi oleh adanya nilai permintaan yang mendekati nol pada beberapa periode.

Pembahasan

Penelitian ini mengembangkan model prediksi permintaan produk untuk UMKM menggunakan ANN yang dioptimasi dengan GA, melibatkan lima variabel input (harga jual, indeks marketing, indeks hari besar, stok tersedia, dan kunjungan media sosial) dengan permintaan produk sebagai variabel target. Variasi data yang signifikan pada beberapa variabel, khususnya permintaan produk, menunjukkan fluktuasi permintaan yang memerlukan metode prediksi mampu menangkap pola hubungan yang kompleks. Proses optimasi hyperparameter menggunakan GA dengan populasi 8, 15 generasi, tiga kali perkawinan induk, mutation rate 20%, seleksi steady-state, dan crossover single-point menunjukkan peningkatan fitness yang signifikan, mencapai nilai terbaik pada generasi kelima, dan stabil hingga akhir proses — menandakan algoritma telah mencapai konvergensi dan menemukan kombinasi parameter yang optimal.

Konfigurasi ANN terbaik yang diperoleh terdiri dari tiga hidden layer dengan 56, 42, dan 26 neuron, learning rate 0,01, batch size 16, optimizer Adam, fungsi aktivasi ReLU pada hidden layer, dan fungsi aktivasi linear pada output layer. Selama pelatihan, kurva loss pelatihan dan validasi menunjukkan pola yang relatif stabil dan saling mengikuti, tanpa indikasi overfitting yang signifikan, yang menunjukkan kemampuan generalisasi model yang baik terhadap data yang digunakan.

Hasil prediksi menunjukkan bahwa model ANN-GA mampu mengikuti pola permintaan aktual dengan baik, termasuk selama periode permintaan puncak. Kinerja model didukung oleh hasil evaluasi berupa MAE sebesar 94,4854, RMSE sebesar 102,5628, MAPE sebesar 21,10%, dan R^2 sebesar 98,89%. Tingkat kesalahan yang relatif rendah dan koefisien determinasi yang mendekati 100% menunjukkan bahwa model mampu menjelaskan hampir seluruh variasi dalam data permintaan. Dengan demikian, kombinasi ANN dan Algoritma Genetika terbukti mampu menghasilkan model prediksi yang akurat dan dapat digunakan untuk mendukung pengambilan keputusan dalam perencanaan produksi, manajemen persediaan, dan pengembangan strategi pemasaran UMKM.

5. KESIMPULAN

Berdasarkan hasil penelitian mengenai pengembangan model prediksi permintaan finished goods pada UMKM Roti Madhani menggunakan Artificial Neural Network yang dioptimasi dengan Algoritma Genetika, dapat disimpulkan bahwa fluktuasi permintaan finished goods pada UMKM Roti Madhani menunjukkan perubahan yang tidak selalu stabil pada setiap periode, sehingga diperlukan metode prediksi yang mampu mengestimasi permintaan secara lebih akurat untuk mendukung pengambilan keputusan produksi dan pengelolaan persediaan. Algoritma Genetika berhasil digunakan untuk menentukan arsitektur ANN yang optimal melalui optimasi terhadap parameter jaringan saraf, sehingga diperoleh konfigurasi ANN terbaik dengan performa prediksi yang lebih baik dibandingkan konfigurasi yang ditentukan secara manual.

Model ANN multi-variabel yang dioptimasi menggunakan Algoritma Genetika berhasil dikembangkan dan mampu memprediksi permintaan finished goods dengan baik, ditunjukkan oleh hasil evaluasi MAE, RMSE, MAPE, dan R^2 yang menunjukkan tingkat akurasi baik dalam mempelajari pola hubungan antarvariabel. Model ANN-GA ini dapat digunakan sebagai alat bantu dalam perencanaan produksi dan pengendalian persediaan pada UMKM Roti Madhani. Untuk penelitian selanjutnya, disarankan menggunakan data historis dengan periode yang lebih panjang, memperluas variabel penelitian dengan faktor eksternal seperti promosi dan kondisi

ekonomi, serta mengimplementasikan model dalam bentuk sistem atau aplikasi berbasis web agar hasil prediksi dapat digunakan secara langsung oleh UMKM dalam pengambilan keputusan.

REFERENSI

- [1] K. Douaioui, R. Oucheikh, O. Benmoussa, and C. Mabrouki, "Machine Learning and Deep Learning Models for Demand Forecasting in Supply Chain Management: A Critical Review," *Applied System Innovation*, vol. 7, no. 5, 2024, doi: 10.3390/asi7050093.
- [2] S. Suardi, M. Hartati, F. S. Lubis, and T. Nurainun, "Optimization of Blood Clam Supply Control Using the Artificial Neural Network (ANN) Method," vol. 7, no. 1, pp. 76–85, 2026, doi: 10.22441/ijiem.v7i1.33669.
- [3] D. S. Prastiya and R. S. Wahyuni, "Artificial Neural Network Model For Optimization of Forecasting Material Inventory," *Jurnal Teknik Industri*, vol. 25, no. 2, pp. 173–188, 2024, doi: 10.22219/jtiumm.vol25.no2.173-188.
- [4] T. A. Pham and H. L. T. Vu, "Optimizing the architecture of the artificial neural network by genetic algorithm to improve the predictability of pile bearing capacity based on CPT results," *Journal of Science and Transport Technology*, vol. 2, no. 1, pp. 1–8, 2022, doi: 10.58845/jstt.utt.2022.en.2.1.1-8.
- [5] S. Oh, J. Yoon, Y. Choi, Y. A. Jung, and J. Kim, "Genetic Algorithm for the Optimization of a Building Power Consumption Prediction Model," *Electronics (Switzerland)*, vol. 11, no. 21, 2022, doi: 10.3390/electronics11213591.
- [6] S. Maitra, "A System-Dynamic Based Simulation and Bayesian Optimization for Inventory Management," *arXiv.org*, 2024.
- [7] P. Cv and S. Medika, "Perancangan Sistem Informasi Persediaan Barang Dengan Pendekatan Supply Chain Management Pada CV. Sarana Medika," *Digibe: Digital Business and Entrepreneurship Journal*, vol. 2, no. 2, pp. 69–87, 2024.
- [8] L. Endahti and M. S. Faturahman, "Predicting Demand for MSME Products Using Artificial Neural Networks (ANN) Based on Historical Sales Data," vol. 8, no. 4, pp. 212–220, 2025.
- [9] W. Wei and J. Chuan, "A combination forecasting method of grey neural network based on genetic algorithm," *Procedia CIRP*, vol. 109, pp. 191–196, 2022, doi: 10.1016/j.procir.2022.05.235.
- [10] H. Ahn, Y. C. Song, S. Olivar, H. Mehta, and N. Tewari, "GNN-based Probabilistic Supply and Inventory Predictions in Supply Chain Networks," pp. 1–15, 2024. [Online]. Available: <http://arxiv.org/abs/2404.07523>
- [11] A. Wahidna, N. Sookia, and Y. K. Ramgolam, "Performance evaluation of artificial neural network and hybrid artificial neural network based genetic algorithm models for global horizontal irradiance forecasting," *Solar Energy Advances*, vol. 4, 2024, doi: 10.1016/j.seja.2024.100054.
- [12] P. Demand, "JURIT Jurnal Riset Ilmu Teknik: A Backpropagation-Based Artificial Neural Network Model for Predicting Pharmaceutical Demand," pp. 1–15, 2025.
- [13] C. M. Lin and Y. S. Lin, "TPTM-HANN-GA: A Novel Hyperparameter Optimization Framework Integrating the Taguchi Method, an Artificial Neural Network, and a Genetic Algorithm for the Precise Prediction of Cardiovascular Disease Risk," *Mathematics*, vol. 12, no. 9, 2024, doi: 10.3390/math12091303.
- [14] A. Yaşar, "A Genetic Algorithm Optimized ANN for Prediction of Exergy and Energy Analysis Parameters of a Diesel Engine Different Fueled Blends," *International Journal of Applied Mathematics Electronics and Computers*, vol. 11, no. 1, pp. 44–54, 2023, doi: 10.18100/ijamec.1262259.
- [15] M. A. Jahin, A. Shahriar, and M. Al Amin, "MCDFN: supply chain demand forecasting via an explainable multi-channel data fusion network model," *Evol. Intell.*, vol. 18, no. 3, 2025, doi: 10.1007/s12065-025-01053-7.