

# Rice Price Forecasting in Padang City for 2025 Using Artificial Neural Network with Backpropagation

Farras Luthfyah Nisa<sup>1</sup>, Dony Permana<sup>1\*</sup>, dan Denny Armelia<sup>2</sup>

<sup>1</sup>Departemen Statistika, Universitas Negeri Padang, Padang, Indonesia

<sup>2</sup>BPS Provinsi Sumatera Barat, Padang, Indonesia

\*Corresponding author: donypermana@fmipa.unp.ac.id

Submitted : 07 Juni 2025

Revised : 25 November 2025

Accepted : 01 Desember 2025

## ABSTRACT

*Rice is a staple food commodity in Indonesia that significantly influences economic stability and food security. In Padang City, rice price fluctuations frequently occur due to high dependence on external supply sources and limited local production, highlighting the need for a reliable predictive system. This study aims to forecast the monthly average retail price of rice in Padang City for the year 2025 using an Artificial Neural Network (ANN) based on the Backpropagation algorithm. The forecasting model is developed using historical rice price data from January 2017 to December 2024. In addition to building the forecasting model, this study evaluates the model's accuracy in capturing the complex and nonlinear patterns of rice price fluctuations.*

**Keywords:** *Artificial Neural Network, Backpropagation, Forecasting, Rice Price.*



This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. ©2025 by author and Universitas Negeri Padang.

## I. PENDAHULUAN

Beras adalah salah satu makanan pokok yang utama dan dikonsumsi hampir oleh seluruh penduduk di Indonesia. Karena perannya yang sangat penting dalam sistem pangan, perubahan harga beras menjadi masalah yang strategis, baik dari segi ekonomi, sosial, maupun politik. Ketika harga beras naik secara tiba-tiba, masyarakat dengan pendapatan rendah akan sangat terpengaruh, sedangkan saat harga merosot secara drastis, petani bisa mengalami kerugian karena harga jual yang lebih rendah dibandingkan dengan biaya produksi (Pragana dkk., 2023). Di Kota Padang, yang merupakan ibu kota Provinsi Sumatera Barat, harga beras sangat fluktuatif. Hal ini tidak hanya disebabkan oleh terbatasnya produksi lokal, tetapi juga karena tingginya ketergantungan pada pasokan dari daerah lain seperti Solok, Tanah Datar, dan Pesisir Selatan (Syafi'i dkk., 2023).

Menurut informasi dari Badan Pusat Statistik, produksi beras lokal di Kota Padang hanya dapat memenuhi sekitar 30% dari kebutuhan konsumsi penduduk setempat. Kondisi ini membuat kestabilan harga sangat tergantung pada pasokan dari luar kota, yang rentan terhadap berbagai faktor seperti kondisi cuaca, biaya pengiriman, dan kebijakan perdagangan antar daerah (Rivani dkk., 2024). Oleh karena itu, pemerintah kota harus memiliki instrumen prediktif yang bisa meramalkan harga beras secara berkala untuk merencanakan kebijakan yang dapat menstabilkan harga, serta untuk mengantisipasi lonjakan harga mendadak yang dapat mengganggu ketahanan pangan masyarakat.

Peramalan harga beras dengan akurat dapat memberikan keuntungan besar dalam pengambilan keputusan. Metode konvensional seperti regresi linier, exponential smoothing, dan ARIMA sering digunakan untuk ramalan harga, namun sering kali hasilnya kurang tepat saat berhadapan dengan pola data yang non-linier dan kompleks, seperti yang terlihat dalam fluktuasi harga beras (Wiranto dkk., 2023). Dalam konteks ini, pendekatan menggunakan Jaringan Saraf Tiruan muncul sebagai pilihan yang menarik karena kemampuannya untuk mendeteksi pola non-linier dari data historis tanpa perlu mengikuti asumsi statistik tertentu (Sawitri dkk., 2018).

Salah satu metode yang paling umum digunakan dalam pelatihan Jaringan Saraf Tiruan adalah Backpropagation. Ini adalah metode pembelajaran dengan menyebarkan galat (error) dari keluaran ke lapisan tersembunyi dan input secara iteratif untuk mengurangi kesalahan dalam prediksi (Az Zahra dkk., 2024). Metode ini telah terbukti efektif dalam berbagai studi tentang peramalan di sektor ekonomi dan pangan, termasuk dalam memprediksi harga beras premium dan medium di berbagai daerah di Indonesia. Penelitian oleh (Safaat dkk., 2020) menunjukkan bahwa Jaringan Saraf Tiruan dengan backpropagation dapat menghasilkan prediksi yang tepat, dengan nilai MSE di bawah 0.001 untuk harga beras premium dan medium.

Disisi lain, dalam penelitiannya (Ngestisari dkk., 2020) melakukan perbandingan antara metode ARIMA dan JST. Dia menemukan bahwa JST dengan arsitektur 12-7-1 menghasilkan Mean Squared Error (MSE) yang lebih rendah, yang membuktikan kelebihanannya dalam mengatasi fluktuasi harga beras musiman. Temuan ini menunjukkan bahwa JST berbasis algoritma backpropagation sangat cocok dan efisien untuk meramalkan harga beras, terutama di daerah seperti Kota Padang yang memiliki ketergantungan tinggi terhadap pasokan dan pola harga yang tidak stabil.

Namun, berdasarkan tinjauan literatur, penelitian yang secara spesifik membahas peramalan harga beras di Kota Padang dengan menggunakan metode Jaringan Saraf Tiruan masih tergolong sedikit, terutama yang menggunakan data historis yang luas dan terbaru. Kebanyakan penelitian hanya menganalisis data dari satu atau dua tahun terakhir, yang menyebabkan ketidakmampuan untuk melihat pola tren musiman jangka panjang. Oleh sebab itu, studi ini bertujuan untuk meramalkan rata-rata harga beras eceran di Kota Padang untuk Tahun 2025 secara bulanan, dengan memakai metode Jaringan Saraf Tiruan berbasis algoritma Backpropagation, dan mengumpulkan data historis dari Januari 2017 hingga Desember 2024. Hasil dari peramalan ini diharapkan dapat digunakan sebagai alat bantu pengambilan keputusan di daerah, pelaku pasar, dan konsumen dalam menghadapi dinamika harga yang akan datang.

## II. METODE PENELITIAN

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik yaitu data rata-rata harga beras di Kota Padang dari Januari 2017 hingga Desember 2024. Data tersebut kemudian digunakan sebagai dasar dalam membangun model peramalan menggunakan Jaringan Saraf Tiruan dengan algoritma Backpropagation. Model ini diterapkan untuk meramalkan harga beras Kota Padang pada tahun 2025.

Backpropagation adalah suatu jenis jaringan saraf tiruan yang termasuk dalam kategori pembelajaran terawasi (supervised learning) dan menggunakan perceptron multilayer. Algoritma Backpropagation dipilih karena mampu mempelajari pola historis harga beras dan menyesuaikan bobot jaringan agar menghasilkan prediksi yang akurat. Dalam penelitian ini, proses implementasi metode dilakukan melalui beberapa tahapan (Wiranto dkk., 2023).

Langkah pertama dalam melakukan Algoritma Backpropagation yaitu melakukan pembagian data. Data harga beras dibagi menjadi dua bagian, yaitu data *training* sebagai data pembelajaran model dan data *testing* sebagai data evaluasi performa model. Pembagian ini mengacu pada prinsip *supervised learning* yang menekankan pelatihan model menggunakan data historis sebelum dilakukan pengujian pada data yang belum pernah dilihat oleh model.

Sebelum melakukan peramalan menggunakan Algoritma Backpropagation, sangat penting untuk melakukan *preprocessing data* terlebih dahulu. Proses *Preprocessing data* yang dilakukan adalah normalisasi *min-max* pada dataset, yang berarti mengubah nilai asli menjadi nilai dalam rentang 0.1 hingga 0.9. Tujuannya adalah untuk memastikan nilai dataset sesuai dengan fungsi aktivasi yang akan digunakan dalam proses pelatihan, sehingga proses pelatihan dapat berjalan optimal. Berikut adalah rumus untuk proses normalisasi *min-max*;

$$z = \frac{(x - \min)}{\max - \min} \quad (1)$$

Keterangan;

$z$  = nilai hasil normalisasi

$x$  = nilai asli/aktual yang akan dinormalisasi

$\min$  = nilai minimum data asli/aktual

$\max$  = nilai maksimum data asli/aktual

Selanjutnya penetapan arsitektur jaringan dilakukan dengan menentukan jumlah neuron pada setiap lapisan sesuai kebutuhan peramalan harga beras menggunakan pendekatan *cross validation* berbasis *sliding window*. Pada lapisan input, jumlah neuron disesuaikan dengan *window size* yang digunakan untuk membentuk data input pada setiap pergeseran window. *Hidden layer* ditetapkan mulai dari 2-12 neuron, yang selanjutnya dipilih berdasarkan kinerja model terbaik. Lapisan output terdiri dari satu neuron karena model memprediksi satu nilai harga pada langkah waktu berikutnya. Setelah struktur jaringan ditentukan, bobot awal setiap lapisan diinisialisasi secara acak sebagai titik awal untuk melanjutkan proses pelatihan model.

Penelitian (Arhami & Nasir, 2020) menjelaskan bahwa ada beberapa langkah yang harus diikuti dalam melakukan proses pelatihan model berdasarkan algoritma backpropagation pada jaringan saraf tiruan.

### Fase I: Propagasi Maju (*Forward Propagation*)

1. Setiap unit di dalam *input layer* menerima sinyal masukan  $x_i$ , dengan  $i = 1, 2, 3, \dots, n$ . Kemudian semua unit pada lapisan tersembunyi berikutnya akan menerima sinyal yang diteruskan. Dengan kata lain, setiap unit di *input layer*

berperan sebagai penyedia sinyal untuk *hidden layer*, mengirimkan sinyal masukan yang diterimanya ke setiap unit dalam *hidden layer* tersebut.

2. Setiap unit pada *hidden layer*, yang dilambangkan sebagai  $z_j$  dengan  $j = 1, 2, 3, \dots, p$ , melakukan penjumlahan dari sinyal input yang telah diberikan bobot.

$$z_{inj} = v_{0j} + \sum_{i=1}^n x_i v_{ij} \quad (2)$$

Setelah itu, nilai keluaran akan dihitung dengan menggunakan fungsi aktivasi yang telah ditentukan.

$$z_j = f(z_{inj}) \quad (3)$$

Selanjutnya, lapisan keluaran atau *output layer* akan menerima sinyal yang akan dikirimkan ke semua unit.

3. Di setiap unit pada lapisan keluaran, yang dilambangkan sebagai  $y_k$  dengan  $k = 1, 2, 3, \dots, m$ , sinyal masukan dari masing-masing lapisan akan dijumlahkan sesuai bobotnya.

$$z_{ink} = w_{0k} + \sum_{j=1}^p z_j w_{jk} \quad (4)$$

Kemudian, nilai keluaran dihitung dengan menggunakan fungsi aktivasi.

$$y_k = f(y_{ink}) \quad (5)$$

### Fase II: Propagasi Mundur (*Backpropagation*)

4. Setiap unit keluaran, yang dilambangkan sebagai  $y_k$  dengan  $k = 1, 2, 3, \dots, m$ , menerima target (output yang diharapkan) untuk dibandingkan dengan hasil output yang dihasilkan.

$$\delta_k = (t_k - y_k) f'(y_{ink}) \quad (6)$$

Faktor  $\delta_k$  ini digunakan untuk menghitung koreksi *error* ( $\Delta w_{jk}$ ) yang akan digunakan untuk memperbarui  $w_{jk}$ , dimana:

$$\Delta w_{0k} = \alpha \delta_k \quad (7)$$

Faktor  $\delta_k$  ini kemudian diteruskan ke lapisan didepannya.

5. Setiap unit di *hidden layer*  $z_j$  dengan  $j = 1, 2, 3, \dots, p$ , unit-unit yang berada di *hidden layer* tersebut akan dijumlahkan untuk mendapatkan nilai delta inputnya:

$$\delta_{inj} = \sum_{k=1}^m \delta_k w_{jk} \quad (8)$$

Selanjutnya hasil tersebut dikalikan dengan turunan dari fungsi aktivasi yang diterapkan oleh jaringan untuk menghasilkan faktor koreksi *error*  $\delta_j$ , dimana:

$$\delta_j = \delta_{inj} f'(z_{inj}) \quad (9)$$

Faktor  $\delta_j$  ini berfungsi untuk menghitung koreksi *error* ( $\Delta v_{ij}$ ) yang kemudian akan digunakan untuk memperbarui  $v_{ij}$ , dimana:

$$\Delta v_{ij} = \alpha \delta_j x_{ki} \quad (10)$$

Disamping itu juga dihitung koreksi bias  $\Delta v_{0j}$  yang nantinya akan digunakan untuk memperbarui  $v_{0j}$ , dimana:

$$\Delta v_{0j} = \alpha \delta_j \quad (11)$$

### Fase III: Perubahan Bobot

6. Setiap unit output  $y_k$  dengan  $k = 1, 2, 3, \dots, m$ , akan mengalami pembaruan pada nilai bobot dan biasnya (dengan  $j = 1, 2, 3, \dots, p$ ):

$$w_{jk}(\text{baru}) = w_{jk}(\text{lama}) + \Delta w_{jk} \quad (12)$$

$$w_{0k}(\text{baru}) = w_{0k}(\text{lama}) + \Delta w_{0k} \quad (13)$$

Setiap unit tersembunyi  $z_j$  (dengan  $j = 1, 2, 3, \dots, p$ ) juga akan mendapatkan pembaruan pada bobot dan biasnya (dengan  $i = 1, 2, 3, \dots, n$ ):

$$v_{ij}(\text{baru}) = v_{ij}(\text{lama}) + \Delta v_{ij} \quad (14)$$

$$v_{0j}(\text{baru}) = v_{0j}(\text{lama}) + \Delta v_{0j} \quad (15)$$

7. Memeriksa *stopping condition*. Jika *stop condition* sudah terpenuhi, maka pelatihan jaringan akan dihentikan. Ada dua metode umum yang digunakan untuk menentukan *stopping condition*, yaitu:
  - a. Menerapkan batas jumlah iterasi yang akan dilakukan.
  - b. Membatasi *error*.

Selanjutnya menghitung nilai *Mean Absolute Square Error* (MAPE). Montgomery (2015) menyatakan bahwa menghitung kesalahan dalam sebuah ramalan penting dilakukan untuk menentukan apakah model yang digunakan sudah efektif. Besaran kesalahan dalam peramalan dapat dihitung menggunakan ukuran kesalahan peramalan. Semakin kecil nilai MAPE yang diperoleh, semakin baik kualitas model peramalan yang digunakan.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left( \frac{y_i - \hat{y}_i}{y_i} \right) \times 100\% \quad (16)$$

Dimana:

$y_i$  = Nilai aktual (target sebenarnya)

$\hat{y}_i$  = Nilai prediksi yang dihasilkan oleh model

$n$  = Jumlah data (sampel)

Chang (2007) menyatakan bahwa ada rentang nilai MAPE yang dapat digunakan sebagai alat untuk menilai seberapa efektif suatu model dalam melakukan peramalan. Rentang nilai MAPE tersebut adalah sebagai berikut;

**Tabel 1.** Selang Nilai MAPE

MAPE	Signifikan
<10%	Kemampuan peramalan sangat baik
10% - 20%	Kemampuan peramalan baik
20% - 50%	Kemampuan peramalan wajar
>50%	Kemampuan peramalan buruk

(Sumber: Chang, 2007).

### III. HASIL DAN PEMBAHASAN

Sebelum memulai analisis jaringan saraf tiruan dengan menggunakan algoritma backpropagation, data perlu dimodifikasi dengan pendekatan time series cross validation menggunakan metode sliding window. Tujuannya adalah untuk mengubah data time series menjadi pasangan input dan output (target) yang dapat dipelajari oleh model.

Selanjutnya, data mengenai Rata-Rata Harga Beras di Kota Padang yang sudah dimodifikasi menggunakan metode sliding window akan mengalami proses normalisasi. Tujuan dari normalisasi ini adalah untuk membuat data lebih stabil, karena data dengan rentang nilai yang besar dapat mengakibatkan ketidakstabilan dalam perhitungan numerik pada model. Data Rata-Rata Harga Beras di Kota Padang untuk periode Januari 2017 – Desember 2024 dinormalisasi sehingga menghasilkan data yang berada dalam rentang nilai 0 hingga 1.

Setelah data diperoleh dalam format yang sudah di normalisasi langkah selanjutnya adalah membagi data menjadi dua bagian, yaitu 80% untuk data *training* dan 20% untuk data *testing*. Oleh karena itu, pola dari data ke-1 hingga ke-67 akan digunakan sebagai data *training*, sedangkan pola dari data ke-68 hingga ke-84 akan menjadi data *testing*. Pembagian data *training* dan data *testing* secara berurut ini dikarenakan dalam penelitian ini data yang digunakan merupakan data *time series*, sehingga sangat memperhatikan urutan waktunya.

Ketika menjalankan algoritma backpropagation, tiga jaringan akan dibentuk, yaitu input layer, hidden layer, dan output layer. Variabel yang digunakan pada input layer adalah X1 sampai X12, yang mewakili setiap bulan selama 12 bulan. Pada pola ini, setiap kali ada kenaikan satu pola, maka input dari X1 hingga X12 juga akan naik ke bulan berikutnya. Sementara itu, jumlah hidden layer yang digunakan tidak terbatas, karena tidak ada ketentuan khusus mengenai jumlah tersebut. Dalam penelitian ini, akan diterapkan satu hidden layer dengan jumlah neuron antara 2 hingga 12 neuron.

Memilih model jaringan saraf tiruan menggunakan algoritma yang didasarkan pada backpropagation melibatkan proses *trial and error* untuk menemukan model yang optimal. Proses ini dilakukan karena jumlah neuron dalam *hidden layer* dapat mempengaruhi tingkat akurasi yang dicapai. Model terbaik ditentukan berdasarkan nilai MAPE terkecil saat melakukan proses testing melalui metode *trial and error*. Tabel 2. menunjukkan 11 model jaringan yang dihasilkan dari metode jaringan saraf tiruan berbasis algoritma backpropagation pada data *training*.

**Tabel 2.** Model Terbaik Data *Training* yang Terbentuk dari *Trial and Error*

Model	Neuron Hidden	MAPE
(12,2,1)	2	30,70%
(12,3,1)*	3	19,14%
(12,4,1)	4	23,22%
(12,5,1)	5	26,41%

(12,6,1)	6	28,08%
(12,7,1)	7	27,04%
(12,8,1)	8	21,35%
(12,9,1)	9	23,56%
<b>(12,10,1)</b>	<b>10</b>	<b>18,15%</b>
(12,11,1)	11	22,00%
(12,12,1)	12	24,30%

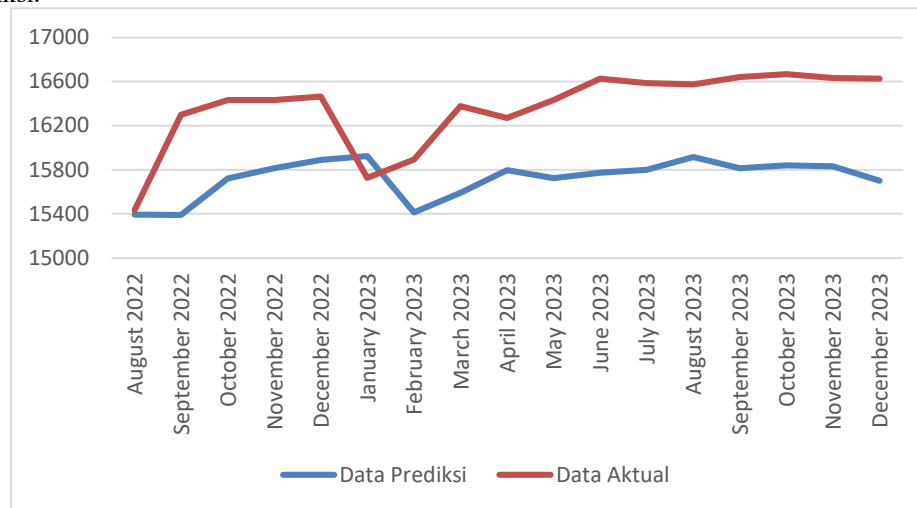
(\*Model Terbaik).

Berdasarkan informasi pada Tabel 2. terdapat 11 model yang dapat digunakan untuk peramalan Data Rata-Rata Harga Beras di Kota Padang. Namun, dari 11 model tersebut yang memenuhi kriteria MAPE terkecil ada pada model JST BP (12,10,1) dengan nilai MAPE sebesar 18,15% yang berarti model memiliki kemampuan peramalan yang baik. Tabel 2. juga menunjukkan bahwa menambah jumlah neuron pada hidden layer tidak menjamin peningkatan kualitas model, karena penambahan neuron pada hidden layer tidak selalu menghasilkan nilai MAPE yang lebih kecil. Meskipun demikian, model ini adalah yang terbaik untuk data rata-rata harga beras di Kota Padang. Selanjutnya, model JST BP (12,10,1) ini akan diuji menggunakan data testing untuk melihat seberapa akurat model yang akan digunakan dalam meramalkan Data Rata-Rata Harga Beras di Kota Padang periode Januari 2025 hingga Desember 2025.

**Tabel 3.** Model Terbaik Data *Testing* yang Terbentuk dari *Trial and Error*


Model	Neuron Hidden	MAPE
(12,10,1)	10	3,99%

Dari Tabel 3. dapat diketahui bahwa model terbaik dari data testing dengan model JST BP (12,10,1) memiliki nilai MAPE sebesar 3,99% yang berarti model memiliki kemampuan peramalan yang sangat baik. Nilai MAPE ini menunjukkan bahwa model ini cukup efektif untuk meramalkan dengan tingkat kesalahan sebesar 3,99%. Berikut ditampilkan grafik garis dari data aktual dan data hasil prediksi pada data testing setelah dilakukan denormalisasi pada data hasil prediksi.



**Gambar 1.** Grafik Garis Data Aktual dan Data Prediksi dari Data *Testing*.

Selanjutnya, peramalan akan dilakukan untuk Rata-Rata Harga Beras di Kota Padang periode Januari 2025 hingga Desember 2025 dengan menggunakan model terbaik dari data *testing*.



**Gambar 2.** Grafik Garis Data Hasil Peramalan Menggunakan Model Terbaik

Berdasarkan Gambar 2. dari peramalan Rata-Rata Harga Beras di Kota Padang menggunakan metode Jaringan Saraf Tiruan berbasis Backpropagation untuk periode Januari 2025 – Desember 2025. Hasil dari peramalan ini menunjukkan adanya tren penurunan harga pada tahun 2025. Diperkirakan harga beras akan berada disekitar Rp15.752,- per kg dan akan terus menurun hingga mencapai Rp14.029,- pada bulan Desember. Penurunan yang signifikan akan terjadi dari Januari hingga Maret, setelah itu penurunan harga akan berlangsung lebih stabil dan bertahap hingga akhir tahun. Tren tersebut menunjukkan bahwa Kota Padang berpotensi untuk mencapai stabilisasi harga beras yang lebih baik pada tahun 2025, dengan adanya kecenderungan harga yang menurun. Hal ini bisa menjadi kesempatan bagi pemerintah daerah dan pelaku pasar untuk merumuskan kebijakan terkait pengadaan, distribusi, serta menjaga kemampuan beli masyarakat terhadap bahan pangan utama.

#### IV. KESIMPULAN

Hasil peramalan menggunakan model Jaringan Saraf Tiruan (JST) berbasis algoritma Backpropagation menunjukkan kinerja yang sangat baik dalam meramalkan rata-rata harga beras di Kota Padang. Arsitektur JST terbaik yang diperoleh adalah JST BP(12,10,1), yang memberikan hasil paling optimal dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 3,99%. Nilai MAPE ini mencerminkan nilai akurasi yang tinggi dan kemampuan model yang sangat baik dalam menangkap pola data yang bersifat *non-linier*. Hasil peramalan Rata-Rata Harga Beras untuk periode Januari 2025 – Desember 2025 menunjukkan hasil peramalan yang mengalami penurunan harga. Terlihat bahwa terjadi penurunan yang signifikan pada Januari hingga Maret. Setelah itu penurunan harga akan berlangsung lebih stabil dan bertahap hingga akhir tahun. Hal ini menunjukkan bahwa Kota Padang berpotensi untuk mencapai stabilisasi harga beras yang lebih baik pada tahun 2025.

Meskipun menghasilkan performa yang baik, penelitian ini memiliki beberapa keterbatasan. Pertama, data yang digunakan hanya mencakup periode hingga tahun 2024 sehingga model sepenuhnya bergantung pada pola historis tanpa mempertimbangkan faktor eksternal seperti kebijakan pangan, gangguan pasokan, atau kondisi iklim yang dapat memengaruhi harga secara tiba-tiba. Kedua, pendekatan Jaringan Saraf Tiruan Backpropagation masih sensitif terhadap penentuan parameter seperti jumlah neuron, *learning rate*, dan *window size*, sehingga hasil model dapat berbeda jika parameter tidak ditetapkan secara optimal.

#### DAFTAR PUSTAKA

- Arhami, M., & Nasir, M. (2020). Data Mining Algoritma dan Pemrograman.
- Az Zahra, F. S., Sumargo, B., Siregar, D., & Fathya, A. Y. (2024). *The Application Of The Artificial Neural Network (ANN) Method For Forecasting The Southern Oscillation Index (SOI)*. 8(2), 179–192.
- Dwira Azi Pragana, Manurung, D. W., & Agus Perdana Windarto. (2023). Analisa Metode Backpropagation Pada Prediksi Rata-rata Harga Beras Bulanan Di Tingkat Penggilingan Menurut Kualitas. *Journal of Computing and Informatics Research*, 2(3), 77–84. <https://doi.org/10.47065/comforch.v2i3.855>

- Ngestisari, W., Susanto, B., & Mahatma, T. (2020). Perbandingan Metode ARIMA dan Jaringan Syaraf Tiruan untuk Peramalan Harga Beras Informasi Artikel Abstrak. *Indonesian Journal of Data and Science (IJODAS)*, 1(3), 96–107.
- Rivani, P., Tessy Octavia Mukhti, Dodi Vionanda, & Dina Fitria. (2024). Artificial Neural Networks to Forecasting the Retail Price of Beras Solok in Padang City using Backpropagation Algorithm. *UNP Journal of Statistics and Data Science*, 2(2), 196–203. <https://doi.org/10.24036/ujsds/vol2-iss2/168>
- Safaat, N., Widiyanto, D., & Chamidah, N. (2020). Implementasi Jaringan Syaraf Tiruan Backproagation Untuk Prediksi Rata-Rata Harga Beras Premium Dan Medium. *Senamika*, 721–732. <https://conference.upnvj.ac.id/index.php/senamika/article/view/618>
- Sawitri, M. N. D., Sumarjaya, I. W., & Tastrawati, N. K. T. (2018). Peramalan Menggunakan Metode Backpropagation. 7(3), 264–270.
- Syafi'i, M., Hasibuan, L. H., Putri, R. K., & Suriani, L. (2023). *Majamath: Jurnal Matematika dan Pendidikan Matematika e-ISSN 2614-4204 dan p-ISSN 2615-465X*. 6, 23–32.
- Wiranto, A. R., Setiawan, E., Nuryaman, A., & Usman, M. (2023). Implementasi Metode Backpropagation Neural Network Dalam Meramalkan Tingkat Inflasi Di Indonesia. *MATHunesa: Jurnal Ilmiah Matematika*, 11(1), 8–16. <https://doi.org/10.26740/mathunesa.v11n1.p8-16>